CRODMA

8th International Scientific Conference CRODMA 2023

Book of Papers

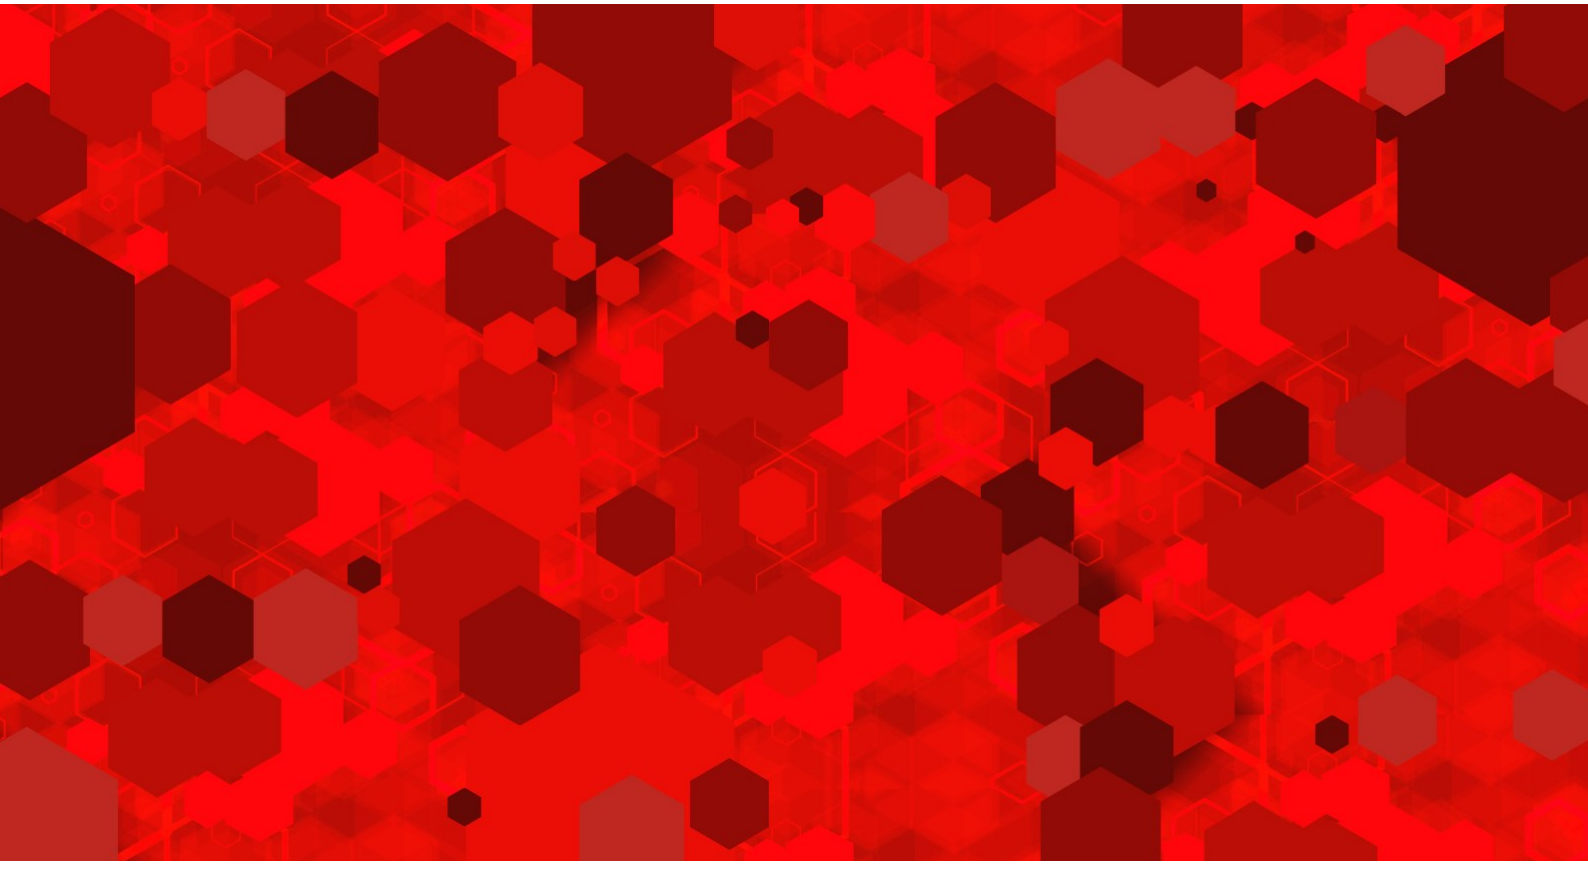

ISSN 2459-7953

CRODMA
Croatian Direct Marketing Association

8th International Scientific Conference CRODMA 2023

BOOK OF PAPERS

October 20th, 2023

Faculty of Organization and Informatics
University of Zagreb

Varaždin, Croatia

8th International Scientific Conference (CRODMA 2023), Book of Papers. Copyright 2023. Croatian Direct Marketing Association. All rights reserved. No part of this publication may be reproduced, stored in a retrieval system, or transmitted in any form, or by any means – electronic, mechanical, photocopying, recording, or otherwise, without the prior permission of the publishers.

Publisher

CRODMA
Croatian Direct Marketing Association
42000 Varaždin
Croatia

For the publisher

Full Prof. Damir Dobrinić, Ph.D. - President of Croatian Direct Marketing Association

Editor in chief

Assoc. Prof. Iva Gregurec, Ph.D.

Editors

Prof. Krasimira Staneva (University of Forestry, Bulgaria)
Prof. Almir Peštek (University of Sarajevo, Bosnia and Herzegovina)
Vladimir Huzjan, Ph.D. (Croatian Academy of Science and Arts)
Ladislav Cvetko, master in library science (University of Zagreb, Croatia)

Technical Editor

Ladislav Cvetko, master in library science

ISSN 2459-7953

Editors disclaim responsibility for language errors.

CRODMA
Croatian Direct Marketing Association

8th International Scientific Conference CRODMA 2023

CONFERENCE CO-ORGANIZERS:

Fakultet ekonomije i turizma
"Dr. Mijo Mirković"

ODJEL ZA EKONOMIJU

Sveučilište
Sjever

CRODMA is a free trade association, which brings together, includes and connects individuals and legal entities engaged in direct and interactive marketing, with the aim of promoting more efficient and more effective management in all areas of Republic of Croatia using the principles, ethics, concepts, knowledge, skills, tools and techniques of direct and interactive marketing. The Association is active in professional and organizational sense independently and in line with the Statute.

MISSION

CRODMA's mission is to support the development and status of direct and interactive marketing as a business strategy.
The mission will be achieved by supporting: development of a legislative framework that will enable prosperity of activities of direct and interactive marketing and market equality of CRODMA members, promotion of activities of direct and interactive marketing to the public (political, economic and general) as a successful business strategy in the prevailing market conditions and education of members and communication of achievements so that the direct and interactive marketing would be properly considered in the domestic and international, primarily European market.

VISION

To become a factor in the development and acceptance of the marketing philosophy as the dominant philosophy of business in Croatia.
CRODMA is focused on the popularization and development of direct and interactive marketing with its members' influence, contacts and activities related to the presentation of ideas and success of direct and interactive marketing for the business, political and general public.

8th International Scientific Conference – CRODMA 2023

20th October 2023, Varaždin, Croatia

PROGRAM COMMITTEE / PROGRAMSKI ODBOR

Prof. Damir Dobrinić	**Program Committee Chair** - President of CRODMA
Vladimir Huzjan Ph.D.	Croatian Academy of Sciences and Arts
Prof. Marina Klačmer Čalopa	University of Zagreb, Croatia
Prof. Vesna Babić Hodović	University of Sarajevo, Bosnia and Herzegovina
Prof. Sanja Bijakšić	University of Mostar, Bosnia and Hercegovina
Prof. Antun Biloš	University of Osijek, Croatia
Prof. Marijan Cingula	University of Zagreb, Croatia
Lecturer Eleonora Mihaela Constantinescu	Christian University, Bucharest, Romania
Prof. Barbara Čater	University of Ljubljana, Slovenia
Prof. Nina Begičević Ređep	University of Zagreb, Croatia
Prof. Branimir Dukić	University of Osijek, Croatia
Assoc. Prof. Iva Gregurec	University of Zagreb, Croatia
Prof. Dóra Horváth	Corvinus University of Budapest, Hungary
Assoc. Prof. Vladimir Kovšca	University of Zagreb, Croatia
Prof. Aleksandra Krajnović	University of Zadar, Croatia
Prof. Momčilo Kujačić	University of Novi Sad, Serbia
Prof. Wilson Ozuem	University of Cumbria, UK
Prof. Jurica Pavičić	University of Zagreb, Croatia
Prof. Almir Peštek	University of Sarajevo, Bosnia and Herzegovina
Prof. Kornelije Rabuzin	University of Zagreb, Croatia
Prof. Drago Ružić	University of Osijek, Croatia
Prof. Anita Ciunova Shuleska	Saints Cyril and Methodius University of Skopje, North Macedonia
Prof. Krasimira Staneva	University of Forestry, Bulgaria
Senior Lecturer Željko Sudarić	College of Applied Sciences Lavoslav Ružička in Vukovar, Croatia
Prof. Marija Tomašević Lišanin	University of Zagreb, Croatia
Prof. Neven Vrček	University of Zagreb, Croatia
Prof. Tamara Vlastelica	University of Belgrade, Serbia
Prof. Ante Rončević	University of North, Croatia
Prof. Davorin Turkalj	University of Osijek, Croatia
Prof. Erik Ružić	Juraj Dobrila University of Pula, Croatia
Prof. Arnela Bevanda	University of Mostar, Bosnia and Hercegovina
Assoc. Prof. Martina Tomičić Furjan	University of Zagreb, Croatia
Assoc. Prof. Ivan Kelić	University of Osijek, Croatia
Assoc. Prof. Katarina Tomičić Pupek	University of Zagreb, Croatia
Assoc. Prof. Igor Pihir	University of Zagreb, Croatia

ORGANIZING COMMITTEE / ORGANIZACIJSKI ODBOR

Assoc. Prof. Iva Gregurec (President)	University of Zagreb, Croatia
Assist. Prof. Zrinka Lacković Vincek	University of Zagreb, Croatia
Prof. Tamara Vlastelica	University of Belgrade, Serbia
Prof. Krasimira Staneva	University of Forestry, Bulgaria

CONTENTS

UTJECAJ MARKETINŠKOG SADRŽAJA NA PONAŠANJE I OSJEĆAJE POTROŠAČA
LARISA HRUSTEK
1

GENDER DIFFERENCES IN GENERATION Z IN CONTEXT OF TRADITIONAL SOCIAL MEDIA USAGE
MATEA MATIĆ ŠOŠIĆ
17

UTJECAJ OGLAŠAVANJA I KORISNIČKI GENERIRANOG SADRŽAJA NA DOŽIVLJAJ O PROIZVODU
DARIJA IVANKOVIĆ, JELENA STJEPANOVIĆ
29

COUNTRY-LEVEL DETERMINANTS OF ATTITUDES TOWARD SCIENCE AND TECHNOLOGY AS PREDICTORS OF THE SOCIAL ROBOTS MARKET
JOSIPA VIŠIĆ
41

OBILJEŽJA ULAGANJA INDIVIDUALNIH INVESTITORA NA FINANCIJSKOM TRŽIŠTU REPUBLIKE HRVATSKE: BIHEVIORALNI FAKTORI I USPJEŠNOST
DINA KORENT, VLATKA KOLEMBUS, MARIJANA BUBANIĆ
51

CUSTOMER ATTITUDES TOWARDS E-COMMERCE: CASE OF BOSNIA AND HERZEGOVINA
ALMIR PEŠTEK, NADIJA HADŽIJAMAKOVIĆ
79

GEN Z AND TRAVEL STORYTELLING: I WANT TO SHARE MY STORY TOO
IVONA MIKULANDRA VOLIĆ, JOSIPA PERKOV, IVONA VRDOLJAK RAGUŽ
91

THE ROLE OF IMMERSIVE TECHNOLOGY ON INTENTION TO VISIT A TOURIST DESTINATION: GEN Z AND SPATIAL PRESENCE EXPECTATIONS
JOSIPA PERKOV, IVONA MIKULANDRA VOLIĆ, ANTE PANJKOTA
101

STRATEŠKO ZNAČENJE INFLUENCERA I DESIGN THINKING U KREIRANJU INTEGRIRANOG KORISNIČKOG ISKUSTVA
MADONNA OJUROVIĆ ČAČIĆ, ANTONIJA RAŽOV, ALEKSANDRA KRAJNOVIĆ
113

RESEARCH OF THE INFLUENCE OF QUALITY PERCEPTION, CUSTOMER SATISFACTION AND BRAND IMAGE ON SPORTS FOOTWEAR BRAND LOYALTY
DAMIR DOBRINIĆ
131

HOW DO WE BEHAVE IN A DIGITAL ENVIRONMENT? – THE IMPACT OF DIGITAL MARKETING ON CONSUMER BEHAVIOR
VALENTINA (ČABULA) MEDVEN, TIHANA CEGUR RADOVIĆ, MIRJANA CIBULKA
145

WEBSITES AS A SALE CHANNEL FOR CHARTER SERVICES IN NAUTICAL TOURISM
SILVIA GOLEM, MARINA BLAŽEVIĆ
161

PRIMJENA STABLA ODLUKE NA PROBLEMU IZLASKA PODUZEĆA NA NOVA TRŽIŠTA
TONI CRLJEN, NIKOLA KADOIĆ, DIJANA OREŠKI
171

ISKUSTVA I STAVOVI HRVATSKIH POTROŠAČA O PRIMJENI PROŠIRENE STVARNOSTI PRILIKOM ONLINE KUPOVINE
ANA KARLICA, DIJANA PLANTAK VUKOVAC
183

PRIMJENA LEAN MENADŽMENTA U POSLOVANJU: METODA SLUČAJA
BRUNO MATAUŠIĆ, MARINA KLAČMER ČALOPA, KAROLINA KOKOT
197

THE EFFECT OF HOTEL ROOM ATTRIBUTES ON HOTEL ROOM PRICES IN SPLIT: A HEDONIC APPROACH
MIHOVIL KOLOVRAT, SLAĐANA PAVLINOVIĆ MRŠIĆ
207

READINESS OF DEVELOPING ECONOMIES' BANKING SECTORS FOR AI-ENHANCED SERVICES: THE EXAMPLE OF THE BANKING SECTOR IN BOSNIA AND HERZEGOVINA
TAMARA TURNADŽIĆ, ALMIR PEŠTEK, MERIMA ČINJAREVIĆ
217

MARKETING U FUNKCIJI PRIVLAČENJA KUPACA U PRODAVAONICU
MIRJANA NEDOVIĆ, ANA NOL, IVONA PERAK
231

MAPPING THE CUSTOMER EXPERIENCE: UNVEILING THE CUSTOMER JOURNEY IN THE NAIL INDUSTRY
DAVOR ŠIROLA, ROBERT STRAHINJA, MAJA ARBANAS
241

MODELIRANJE TROŠKOVA PRIBAVE ZA UNAPRJEĐENJE PRODAJE NEŽIVOTNIH OSIGURANJA
TICIJAN PERUŠKO, DANIJELA PAULIĆ
253

UČINKOVITOST UI TEHNOLOGIJA PRI GENERIRANJU OGLASNIH PORUKA – EKSPLORATIVNO ISTRAŽIVANJE PERCEPCIJE POTENCIJALNIH KUPACA
BRUNO KRNETA, ERIK RUŽIĆ
263

IZVORI INFORMIRANJA KOJI IMAJU NAJVEĆI UTJECAJ NA ODLUKU O KUPNJI PROIZVODA ZA NJEGU „PROBLEMATIČNE“ KOŽE LICA PRIPADNIKA GENERACIJE Z
MIROSLAV MANDIĆ
275

USE OF CHATGPT AND GPT-4 ARTIFICIAL INTELLIGENCE SYSTEMS IN MARKETING: A REVIEW OF EARLY RESEARCH STUDIES AND PRACTICES
GORAN BUBAŠ, ANA KUTNJAK
287

DIGITALNI NOMADI – ISTRAŽIVANJE NA PRIMJERU POTENCIJALA GRADA SPLITA I NJEGOVE OKOLICE
ZORAN MIHANOVIĆ, NIKOLA JUKIĆ
297

PODIZANJE RAZINE INTEROPERABILNOSTI TEMELJNIH REGISTARA O OSOBAMA U RH
DARKO GULIJA, KORNELIJE RABUZIN, LEO MRŠIĆ, NIKOLA MODRUŠAN, PETAR GULIJA
311

DRUŠTVENO ODGOVORNO POSLOVANJE U BANKARSKOM SEKTORU NA PODRUČJU REPUBLIKE HRVATSKE
NIKOLINA ŽUPANIĆ, MARINA KLAČMER ČALOPA, IVANA ĐUNĐEK KOKOTEC
323

MIGRATING DATA TO THE CLOUD: AN ANALYSIS OF CLOUD STORAGE PRIVACY AND SECURITY ISSUES AND SOLUTIONS
MARIJA KUŠTELEGA, RENATA MEKOVEC
333

ELEKTRODERMALNA AKTIVNOST U ISTRAŽIVANJIMA U TURIZMU – BIBLIOMETRIJSKA ANALIZA
IVANA PAVLIĆ
343

PREGLED RAZVOJA TEORIJE USLUŽNOSTI PRIMJENOM METODA BIBLIOMETRIJSKE ANALIZE
NIKOLINA POSARIĆ, LORENA PIKL
361

BIHEVIORALNA EKONOMIJA U MARKETINGU I ARHITEKTURA IZBORA
KARMEN GREGOV, ALEKSANDRA KRAJNOVIĆ, JURICA BOSNA
373

ULOGA PROCESA I TEHNOLOGIJA UPRAVLJANJA ZNANJEM U MARKETINGU
SANDRA LOVRENČIĆ, IVA GREGUREC, BRUNO ČOLAN
385

FOREST RECREATION TOURISM - HEALTH PREVENTION AND WELFARE FOR CYBER SOCIETY PART 1 FOREST GREEN SYSTEM
KRASIMIRA STANEVA, MARTIN MARINOV
401

DRUŠTVENA ODGOVORNOST, SNAGA BRANDA I PEROFRMANSE PODUZEĆA
ANITA TALAJA, SLAVKO ŠODAN, IVAN MERŠA
409

STAVOVI STANOVNIŠTVA O UVOĐENJU EURA U REPUBLIKU HRVATSKU
ZRINKA LACKOVIĆ VINCEK, VLADIMIR KOVŠCA, HANA HANŽEK
417

ETIČNOST U OGLAŠAVANJU MODNIH BRENDOVA NA DRUŠTVENIM MREŽAMA: PERCEPCIJA MLADIH
DIANA PLANTIĆ TADIĆ, JADRANKA IVANKOVIĆ, ANA KLASNIĆ
435

DIGITALNA TRANSFORMACIJA KNJIGOVODSTVENOG SERVISA U KONTEKSTU ONLINE DOHVATA I AUTOMATSKE OBRADE e-RAČUNA i e-IZVODA BANKE
STJEPAN VIDAČIĆ
449

MANIPULATIVNE PRIJETNJE UMJETNE INTELIGENCIJE
DAMIR DOBRINIĆ
467

KORIŠTENJE ASERTIVNE TEHNIKE U PRODAJNOM POSLOVANJU
SANDRA MRVICA MAĐARAC, ZVONIMIR FILIPOVIĆ, SLAĐANA BRAJEVIĆ
483

Original scientific paper / Izvorni znanstveni rad

UTJECAJ MARKETINŠKOG SADRŽAJA NA PONAŠANJE I OSJEĆAJE POTROŠAČA

LARISA HRUSTEK
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
lhrustek@foi.unizg.hr

SAŽETAK

Digitalno doba i brojne funkcionalnosti digitalnih tehnologija omogućile su organizacijama sveprisutnost u životu čovjeka. Sve učestalije, potrošači su obasipani različitim marketinškim sadržajem i mogućnostima odabira proizvoda i usluga. Potrošači u bilo kojem trenutku imaju pristup atraktivnim ponudama na tržištu putem društvenih mreža, e-maila, mobilnih poruka i drugih oblika dijeljenja marketinškog sadržaja. Postavlja se pitanje privlači li kupce na nepotrebnu kupovinu i nerazumnu potrošnju sveprisutni marketinški sadržaj s primamljivim ponudama ili ne. Naime, veliki broj kupaca koristi pogodnosti marketinških sadržaja i pristaje na kupnju proizvoda i usluga koji im možda nisu potrebni. Slabost na primamljive ponude i prekomjerna potrošnja mogu kod potrošača izazvati negativne osjećaje kao što su krivnja, tuga ili zabrinutost, no također, mogući su i pozitivni osjećaji kao olakšanje, sreća i zadovoljstvo. Rad prikazuje teorijski okvir utjecaja različitih oblika marketinškog sadržaja na proces donošenja odluke o kupnji kao i osjećaje kupaca nakon obavljene kupnje.

U svrhu prikupljanja primarnih podataka provedeno je kvantitativno istraživanje kako bi se dobio uvid o utjecaju marketinških sadržaja i ponuda u digitalnom okruženju na ponašanje i osjećaje potrošača. Pritom su ciljevi istraživanja utvrditi utjecaj sveprisutnog marketinškog sadržaja na ponašanje potrošača i njihovo donošenje odluka o kupnji te ispitati njihove osjećaje nakon izvršene kupnje.

KLJUČNE RIJEČI: marketinški sadržaj, digitalno oglašavanje, ponašanje potrošača, osjećaji potrošača

THE INFLUENCE OF CONTENT MARKETING ON CONSUMER BEHAVIOR AND SENTIMENTS

ABSTRACT

The digital age and the many features of digital technologies have enabled businesses to be ubiquitous in people's lives. Consumers are increasingly engaging with different marketing content and options for choosing products and services. Through social networks, e-mail, mobile messaging and other forms of shared content marketing, consumers have access to attractive offers in the marketplace at all times. The question is whether or not the ubiquitous content marketing with enticing offers is tempting customers to make unnecessary purchases and unwise consumption. After all, many customers take advantage of content marketing and agree to buy products and services they may not even need. Weakness to tempting offers and overconsumption can trigger negative feelings in consumers such as guilt, sadness, or worry, but positive feelings such as relief, happiness, and satisfaction are also possible. In the paper, the theoretical framework of the influence of different content marketing on the decision-making process about the purchase is presented, as well as the sentiments of customers after making a purchase are discussed.

In order to collect primary data, quantitative research was conducted to gain insight into the impact of content marketing and offers in the digital environment on consumer behaviour and sentiments. The main objectives of the research are to determine the impact of ubiquitous content marketing on consumer behaviour and purchase decision-making as well as to examine their sentiments after making a purchase.

KEYWORDS: content marketing, digital advertising, consumer behaviour, consumer sentiments

1. UVOD

Digitalno doba karakterizirano upotrebom digitalnih tehnologija i online povezanošću, dovelo je do značajnih promjena u pristupu potrošačima od strane organizacija što se reflektira na njihovo ponašanje i donošenje odluke prilikom kupnje [Polanco-Diges & Debasa, 2020]. Organizacije koriste sve mogućnosti različitih pristupa, s namjerom kreiranja privlačnih i informativnih marketinških sadržaja, koji utječu na ponašanje potrošača u digitalnom okruženju [Munsch, 2021]. Predviđa se da će digitalni marketing u narednim godinama značajno rasti s godišnjom stopom rasta od 9%, odnosno globalno tržište digitalnog oglašavanja i marketinga dosegnut će 786,2 milijarde dolara do 2026. godine [Markets, 2022]. Marketinški stručnjaci usmjeravaju svoja ulaganja u kreiranje različitih oblika digitalnih marketinških sadržaja i kanale distribucije kako bi doprli do potrošača te potaknuli i usmjerili njihovu kupnju [Munsch, 2021]. To im omogućuju digitalne platforme i mediji uz pomoć kojih prate ponašanje potencijalnih kupaca nudeći im prilagođene ponude po mjeri, dok kupci preuzimaju odlučujuću ulogu uz aktivno sudjelovanje u razmjeni mišljenja, dojmova i iskustva stvarajući različite oblike sadržaja o proizvodima i uslugama [Mendoza-Moreno & Turriate-Guzmán, 2022].

Različite digitalne platforme i mediji potiču primjenu i širenje marketinga sadržaja (eng. content marketing). Marketing sadržaja (ili sadržajni marketing) podrazumijeva tekstualnu

i/ili grafičku informaciju čija je osnovna svrha privlačenje, angažiranje, zadržavanje i ponovno vraćanje kupca radi ostvarenja određenih poslovnih ciljeva. Glavna uloga sadržaja je da zainteresira potencijalne kupce uz pričanje zanimljivih priča. U digitalnom okruženju dostupni su različiti digitalni mediji i komunikacijski kanali za distribuciju sadržaja, a prema vlasništvu oni mogu podijeliti na plaćene, zarađene, dijeljene i vlastite medije, dok sudionici u cijelom procesu mogu biti tvrtke, angažirani marketinški stručnjaci ili agencije, ali i neplaćeni pojedinci koji dijele informacije o proizvodima i/ili uslugama [Dobrinić, 2023]. Distribucijski mediji i kanali omogućuju svakodnevno prisustvo te značajno utječu na donošenje odluka o kupnji. Također, kanali putem kojih informacije o proizvodima ili uslugama dolaze do potencijalnih kupaca mogu imati značajnu ulogu u formiranju ponašanja i donošenja odluka. Tvrtke te influenceri i blogeri na društvenim mrežama, različiti organizirani događaji, informacije dostupne e-mailom, mobilnim porukama ili na platformama više nego ikad pružaju pristup marketinškim sadržajima s atraktivnim ponudama proizvoda i usluga [Saura et al., 2020]. Privlačne i primamljive ponude proizvoda i usluga kreiraju nove želje i potrebe kupaca što može rezultirati nepotrebnom i nerazumnom potrošnjom, a posljedično tome kod kupaca se razvijaju pozitivni i/ili negativni osjećaji.

Glavni cilj ovog rada je istražiti privlači li kupce na kupnju sveprisutni marketinški sadržaj s primamljivim ponudama ili ne. Povezano s time, ispitat će se reakcije potrošača na različite distribucijske kanale dostupnog marketinškog sadržaja, odnosno utječe li dostupan marketinški sadržaj na povećanu kupnju. S obzirom na to da je ponašanje potrošača pod snažnim utjecajem marketinškog sadržaja, što može utjecati na njihovu odluku o kupnji, kod potrošača su mogući pozitivni i/ili negativni osjećati. Sukladno tome istražit će se kakve osjećaje izaziva potrošnja kod potrošača.

U sljedećem poglavlju predstavljeno je teorijsko polazište istraživanja gdje su pojašnjeni oblici distribucije marketinškog sadržaja u digitalnom okruženju te njihov utjecaj na ponašanje potrošača, a posljedično tome, i osjećaji prisutni kod potrošača prilikom kupnje. Treće poglavlje pruža uvid metodologije provedenog istraživanja i prikupljenih materijala. U četvrtom poglavlju prikazani su rezultati istraživanja kroz osvrt na iste. U konačnici, rad je finaliziran zaključkom te su navedena ograničenja istraživanja i budući istraživački planovi.

2. TEORIJSKO POLAZIŠTE

2.1. DISTRIBUCIJA MARKETINŠKOG SADRŽAJA U DIGITALNOM OKRUŽENJU

Distribucija marketinškog sadržaja doživjela je procvat s obzirom na to da različiti digitalni mediji i komunikacijski kanali otvaraju sva vrata pristupa potencijalnim potrošačima, svih dobnih granica, preferencija i interesa. Spomenuto rezultira svakodnevnom okupiranošću ponudama proizvoda i/ili usluga. Potencijalni potrošači za takve ponude mogu pokazati interes, dok s druge strane, iste ne trebaju biti u njihovom fokusu, ali ipak ima pristup informacijama koje vrlo lako pronalaze put do njih. Svjesno ili nesvjesno, potrošači su obasipani primamljivim ponudama koje mogu formirati njihovo ponašanje i izgraditi nove potrošačke navike. U nastavku će biti predstavljeni najpoznatiji oblici distribucije sadržaja kroz medije i kanale, što će radi lakšeg razumijevanja biti predstavljeno kroz PESO model (engl. Paid, Earned, Shared i Owned) [Plessis, 2022]. PESO model uključuje oblike distribucije sadržaja koji se dijele prema vlasništvu na plaćene, zarađene, dijeljene i vlastite [Plessis, 2022].

Prema PESO modelu, plaćeni mediji predstavljaju kanale kroz koje se sadržaj dijeli, a svaka njihova objava se plaća. Tu je uključeno plaćeno oglašavanje na društvenim mrežama, tražilicama, ali i klasičnim medijima poput radija i televizije. Zarađeni medij podrazumijeva promociju proizvoda i usluga bez naplate, a sadržaj se obično distribuira putem trećih strana. Dijeljeni medij podrazumijeva različite opcije dijeljenja marketinškog sadržaja putem društvenih mreža, foruma ili drugih platformi, a u dijeljenje mogu biti uključeni svi, odnosno potrošači koji samostalno kreiraju sadržaj. Vlastiti medij uključuje promociju kroz kanale koje kreira i posjeduje organizacija te ih koristi za prezentaciju proizvoda i/ili usluga. Kako je cilj organizacija doprijeti do potencijalnih potrošača, ovi mediji često se kombiniraju te postoje različiti strateški pristupi u komunikaciji i predstavljanju sadržaja. Digitalne tehnologije podržavaju pristup kupcima na različite načine, no važno je prepoznati kojim kanalom informacije najlakše nalaze zainteresiranu publiku tj. tko ili kako potiče potrošača na kupnju. Osim digitalnih kanala, razlikuju se i angažirani subjekti te način na koji se sadržaj predstavlja. Tako se sadržaj može distribuirati na platformama, društvenim mrežama, portalima, tražilicama, radiju, televiziji ili putem e-maila, mobilnih poruka te drugih medija. Inicijator predstavljanja sadržaja može biti tvrtka, plaćena agencija ili stručnjaci, influenceri, blogeri i utjecajne osobe, kao i privatne osobe bez ikakvog angažmana. Način prijenosa informacija i predstavljanja sadržaja se razlikuje te može biti u obliku videa, snimljene priče i elektroničke usmene predaje (engl. e-WOM), teksta, slike, infografike i drugo.

U nastavku su spomenuti najpoznatiji oblici distribucije marketinškog sadržaja, a to su:

- Marketinški sadržaj i ponude distribuirane na društvenim mrežama ili platformama tvrtke
- Marketinški sadržaj i ponude distribuirane na tražilicama, portalima, radiju i televiziji u angažmanu tvrtke
- Marketinški sadržaj i ponude distribuirane na društvenim mrežama ili platformama influencera, blogera ili drugih utjecajnih osoba
- Marketinški sadržaj i ponude distribuirane na društvenim mrežama, platformama ili portalima temeljem iskustva, recenzija i sadržaja kreiranog od potrošača (neplaćeni predstavnici)
- Marketinški sadržaj i ponude distribuirane e-mailom, mobilnim porukama ili direktno potrošačima kroz platforme (npr. Viber i drugo) [Saura et al., 2020].

Ovo su najčešći oblici predstavljanja marketinškog sadržaja, a kojima se nastoji utjecati na ponašanje potrošača [Saura et al., 2020]. Marketinški sadržaj na društvenim mrežama i platformama tvrtke podrazumijeva distribuciju sadržaja poput video materijala, audio sadržaja, slika ili nekog drugog oblika sadržaja distribuiranog preko društvenih mreža ili službene platforme tvrtke [Dobrinić, 2023]). To su sadržaji kreirani i distribuirani direktno od tvrtke s namjerom privlačenja kupaca i utjecaja na njihovo ponašanje. Na taj način, tvrtke prikupljaju informacije o svojim kupcima i prate njihovo ponašanje sa svrhom upoznavanja njihovih želja i preferencija [Saura et al., 2020]. Podaci koje korisnici generiraju kao rezultat aktivnosti na društvenim mrežama, web stranicama, digitalnim platformama ili u interakciji, stvaraju podatkovne točke koje nude važne informacije o demografskim i geografskim karakteristikama potencijalnih kupaca, kao i njihovim interesima i životnim navikama [Saura et al., 2020]. Tvrtke neprestano traže nove strategije i načine u svojim marketinškim planovima kako bi povećale svoj doseg u digitalnom okruženju [Matin et al., 2022]. Stoga, tragaju za drugim oblicima distribucije sadržaja kako bi ostavili traga na tržištu i utjecali na donošenje odluke o kupnji kod potrošača.

Marketinški sadržaji i ponude s kodovima za popust, nagradne igre ili pak promocija određenih proizvoda i usluga od strane influencera vrlo je raširen oblik distribucije. Influenceri, slavne osobe i blogeri aktivne su internetske ličnosti s dovoljno pratitelja i zainteresirane publike da utječu na određeni dio tržišta [Matin et al., 2022], [Lou, 2022]. Influenceri, kroz predstavljanje svakodnevnog života i svojih iskustava, imaju cilj pridobiti što veći broj pratitelja, s namjerom dugotrajnog utjecaja na odluke kupaca o kupnji. Sve veći broj tvrtki traži usluge utjecajnih osoba kako bi im isti osigurali blizak odnos kupaca s njihovim brendom, čime se posljedično stvara ljubav prema brendu [Matin et al., 2022]. Ovakav oblik distribucije sadržaja omogućio je influencerima aktivnu ulogu u cijelom procesu čime mogu uvjeriti i usmjeriti radnje potencijalnih kupaca [Mendoza-Moreno & Turriate-Guzmán, 2022]. Da bi se predstavili proizvodi i usluge organiziraju se marketinški događaji koji okupljaju zainteresiranu publiku ili pak se u sklopu nekih događaja organizira predstavljanje proizvoda ili usluga široj javnosti.

Marketinški sadržaj i ponude dijeljene temeljem iskustva, recenzija i sadržaja kreiranog od korisnika/kupaca također su čest oblik predstavljanja određenih proizvoda i usluga. Naime, u ovom slučaju češće je riječ o pojedincima koji nisu novčano angažirani za promociju, već samostalno iskazuju interes za određenom skupinom proizvoda ili usluga, a što je temeljeno na njihovom iskustvu, te time svjesno ili nesvjesno utječu na odluku o kupnji kod drugih ljudi.

Usmena predaja nekad je bio jedan od najčešćih oblika prijenosa informacija o proizvodima i uslugama, ali još i danas je ovo vrlo raširen oblik promocije, ali u digitalnom obliku [Dobrinić, 2023]. E-mail, mobilne poruke ili platforme za razmjenu tekstualnih ili glasovnih poruka poput Vibera omogućuju direktan pristup potencijalnim kupcima, a ponude kakve im se nude vrlo su privlačne i izazivaju potrebu da istraže određene proizvode i/ili usluge, i na kraju, da ih posjeduju.

2.2. UTJECAJ DIGITALNOG OGLAŠAVANJA NA PONAŠANJE POTROŠAČA

Potrošačko ponašanje posljednjih dvadesetak godina obilježeno je značajnim promjenama uz prisutnost digitalnih tehnologija i sadržaja koji je dostupan u digitalnom okruženju. S jedne strane, tvrtkama je omogućen brz i jednostavan pristup kupcima te praćenje kupaca i prikupljanje podataka o njima, dok je istovremeno teže prepoznati one ključne informacije i otkriti odgovarajući pristup potencijalnom kupcu čime je povjerenje kupaca narušeno i vrlo lako ga je izgubiti [Figueiredo et al., 2021]. Štoviše, tvrtke se poznavanjem ponašanja svojih kupaca, lakše mogu prilagoditi njihovim potrebama koristeći strategije sadržajnog marketinga. Te su strategije ključne za povećanje prodaje i razvoj poslovanja, budući da povećavaju angažman korisnika i utječu na njihovo ponašanje [Saura et al., 2020]. Digitalno okruženje za tvrtke omogućuje stjecanje vidljivosti, povećanje prodaje i pozicioniranje u svijesti kupca [Mendoza-Moreno & Turriate-Guzmán, 2022]. S druge strane, kupci lako pronalaze proizvode i usluge po mjeri, no u moru ponuda, često lako griješe u izboru ili kupuju nepotrebno i previše.

Digitalno oglašavanje i dijeljenje sadržaja, praćeno glazbom, grafikom, humorom ili uključivanjem interesantnih, utjecajnih pojedinaca, je informativno i privlačno te utječe na ponašanje potencijalnih kupaca [Munsch, 2021]. Istraživanja su pokazala da društveni mediji pozitivno utječu na razinu svijesti o brendu i njegov imidž, a povjerenje u sponzorirani sadržaj raste [Matin et al., 2022] te posljedično tome dovodi do uvjeravanja i usmjeravanja radnji potrošača [Mendoza-Moreno & Turriate-Guzmán, 2022]. No, postoje i oprečna razmišljanja,

posebice koja se odnose na ulogu influencera, što je korisnike potaknulo na detaljnije razmatranje promocije i sadržaja putem ovih kanala. Sve veći broj korisnika preispituje autentičnost preporuka influencera na društvenim mrežama [Matin et al., 2022].

U pozitivnom kontekstu, digitalno okruženje i dostupni marketinški sadržaji utječu na ponašanje potrošača omogućujući sljedeće:

- pristup širokoj ponudi proizvoda i/ili usluga iz bilo kojeg dijela svijeta,
- pristup detaljnim informacijama o proizvodima i/ili uslugama,
- dostupnost i pregledavanje recenzija o proizvodima i/ili uslugama,
- usporedba proizvoda i/ili usluga,
- dijeljenje vlastitih iskustava o proizvodima i/ili uslugama,
- mogućnost zarade kroz usluge promocije [Alkharabsheh & Zhen, 2021], [Ahmad & Rosli, 2023].

U negativnom kontekstu, marketinški sadržaji u digitalnom okruženju ogledaju se u ponašanju potrošača kroz sljedeće:

- povećana kupnja nepotrebnih stvari,
- veća potrošnja,
- nemogućnost kontrole kod potrošnje,
- prividna slika o dobrim prihvatljivim ponudama,
- gubitak vremena na praćenje marketinškog sadržaja,
- opterećenost ponudama i stvaranje prividnih potreba [Quora, n.d.].

2.3. OSJEĆAJI POTROŠAČA NAKON KUPNJE

Sveprisutni marketinški sadržaj s primamljivim ponudama potiče kupce na impulzivnu kupnju. Istraživanja su pokazala da impulzivna kupnja može pružiti trenutno poboljšanje raspoloženja [Anderson, 2020], [Barta et al., 2021]. Provedeno istraživanje reklo je da za čak 2 od 3 ispitanika impulzivna kupnja ima pozitivan utjecaj na njihovo raspoloženje te da može loš dan pretvoriti u dobar [Anderson, 2020]. Također, digitalno okruženje i online predstavljanje proizvoda i usluga pozitivno utječe na namjeru kupnje izazivajući emocionalno stanje poput zadovoljstva i uzbuđenja [Tong et al., 2022]. Suprotno tome, neka istraživanja govore o tome kako impulzivna kupnja može dovesti do žaljenja te pojedinci mogu osjećati slabost zbog trenutka prepuštanja i provedene nepotrebne kupovine [Lim et al., 2017].

Veliki broj istraživanja naglasak stavlja na osjećaje i emocije pojedinca u procesu korisničkog putovanja i kupnje [Wang et al., 2021], dok je izostavljeno proučavanje emocionalnih posljedica nakon kupnje, što je predmet ovog istraživanja. Osjećaji i emocije u procesu korisničkog putovanja mogu se podijeliti na pozitivne i negativne. Emocionalni čimbenici na kojima je naglasak u digitalnom okruženju su ljutnja, strah, tuga, sram, zadovoljstvo i sreća [Cinar, 2020].

U nastavku je prikazan poznati Russellov kružni model emocija koji će biti korišten u ovom istraživanju gdje se osjećaji i emocije potrošača promatraju kroz dvije dimenzije, valenciju i uzbuđenje, a sve je prikazano kružno na način da su suprotne emocije poput primjerice, sreće i tuge na suprotnim stranama (Slika 1). Svaka emocija može se smatrati linearnom kombinacijom ovih dviju dimenzija ili različitih stupnjeva valencije i uzbuđenja [Feldman Barrett & Russell, 1998], [Posner et al., 2005], [Yarwood, n.d.]. Valencija predstavlja kriterij instinktivno generiranih emocija kojim se određuje jesu li osjećaji pozitivni, negativni ili

neutralni. Uzbuđenje je povezano s emocijama što se usko odnosi na procjenu značaja događaja ili fizički intenzitet podražaja osobe [Niven & Miles, 2013].

Slika 1. Russellov kružni model emocija

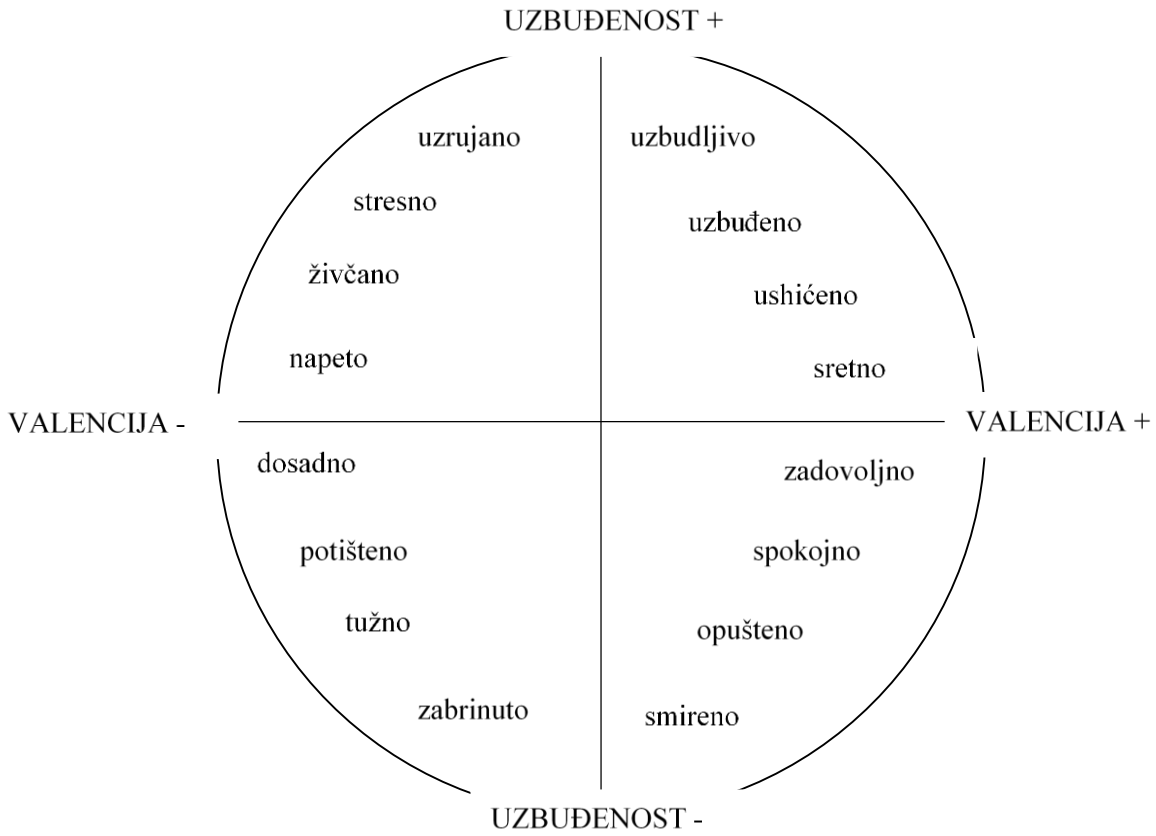

Izvor: [Barrett & Russell, 1998]

Rusellov kružni model emocija poslužio je za opis pozitivnih i negativnih emocija prisutnih kod potrošača prilikom i nakon kupnje.

3. METODOLOGIJA I MATERIJALI

Prethodno poglavlje pružilo je uvid u teorijski pregled literature temeljen na sekundarnim izvorima podataka u vidu znanstvenih članaka referenciranih u ovom radu. Sukladno tome, na Slici 2 prikazan je teorijski okvir ovog istraživanja. Teorijski okvir pruža pregled istraživane teme, a što se odnosi na utjecaj različitih oblika marketinškog sadržaja u procesu donošenja odluke o kupnji te posljedično tome, utjecaj istog na osjećaje kupaca nakon obavljene kupnje.

Slika 2. Teorijski okvir istraživanja

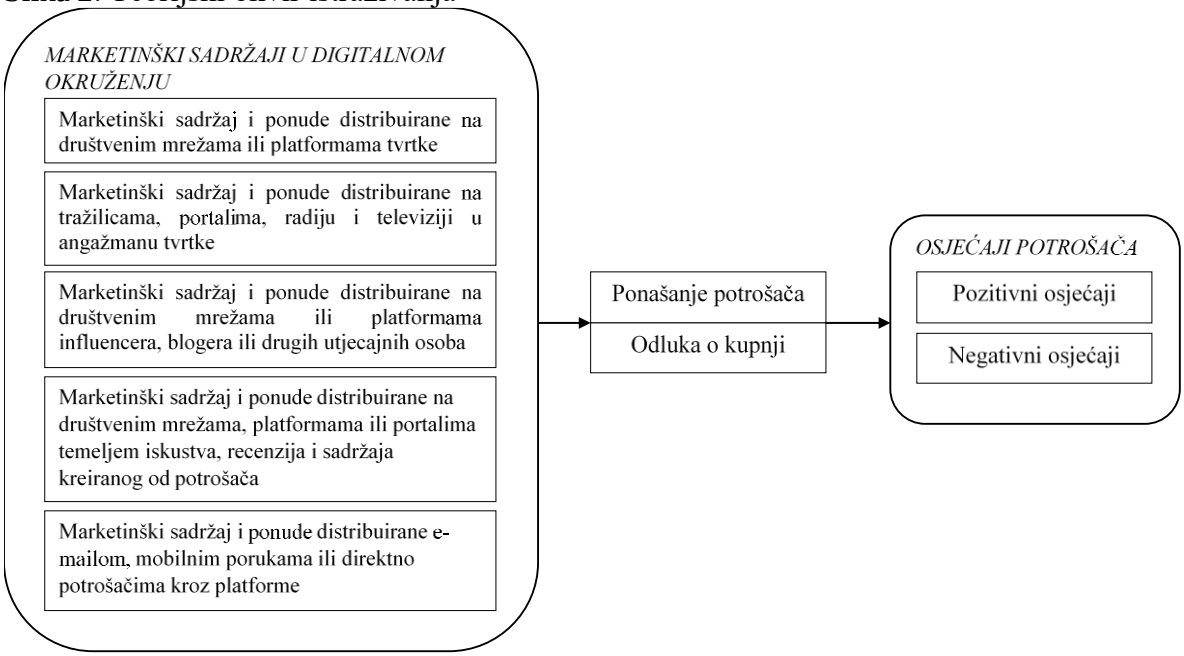

Izvor: izrada autora

Također, teorijski okvir poslužio je kao polazište za kvantitativno istraživanje i kreiranje anketnog upitnika. Kvantitativno istraživanje provedeno je kako bi se prikupili primarni podaci za analizu utjecaja marketinških sadržaja i ponuda u digitalnom okruženju na ponašanje i osjećaje potrošača. Anketni upitnik kao instrument prikupljanja primarnih podataka bio je podijeljen na društvenim mrežama LinkedIn i Facebook. Sastojao se od ukupno 21 pitanja podijeljenih u 3 kategorije: *Osnovne informacije o ispitanicima*, *Utjecaj marketinških sadržaja i ponuda na ponašanje potrošača* te *Osjećaji i emocije izazvani potrošnjom*. Kategorija *Osnovne informacije o ispitanicima* uključila je 4 pitanja koja su se odnosila na demografske karakteristike, kategorija *Utjecaj marketinških sadržaja i ponuda na ponašanje potrošača* uključila je 11 pitanja te kategorija *Osjećaji i emocije izazvani potrošnjom* 6 pitanja. Pitanja su bila sastavljena temeljem teorijskog okvira pri čemu je bio moguć odabir jedne od ponuđenih opcija ili višestruki odgovor, a ispitanicima je bilo na raspolaganju odabir opcija dodavanja odgovora ili pak odabir opcije ničeg od navedenog.

Sukladno rezultatima teorijskog pregleda literature, definirana su sljedeća istraživačka pitanja (IP):

- IP 1: Utječe li marketinški sadržaj na ponašanje potrošača i njihovu odluku o kupnji te koji oblici distribucije marketinškog sadržaja imaju najveći utjecaj na njihovo ponašanje?
- IP 2: Kako se kupci osjećaju pod utjecajem sveprisutnog marketinškog sadržaja?

Podaci prikupljeni kvalitativnim istraživanjem, analizirani su i predstavljeni u sljedećem poglavlju. Uzorak ispitanika kojima je bio namijenjen anketni upitnik bio je namjeran.

4. REZULTATI

Istraživanjem je obuhvaćeno ukupno 53 ispitanika, a svi ispitanici u potpunosti su odgovorili na sva pitanja. Prema demografskim karakteristikama, u istraživanju je sudjelovalo 86,8% pripadnica ženskog spola, a preostalih 13,2% bili su pripadnici muškog spola. Najviše

ispitanika (64,2%) u starosti su između 25 i 34 godine, a istraživanju nije pristupio niti jedan ispitanik u dobnim granicama ispod 15 godina i iznad 55 godina.

Tablica 1. Demografske karakteristike ispitanika

Varijable	**Karakteristike**	**Frekvencija**	**Postotak**
Spol ispitanika	Ženski	46	86,8%
	Muški	7	13,2%
Dobna skupina	> 15	0	0%
	15 – 24	8	15,1%
	25 – 34	34	64,2%
	35 – 44	10	18,9%
	45 – 54	1	1,9%
	55 – 64	0	0%
	< 65	0	0%
Obrazovanje	Nezavršena osnovna škola	0	0%
	Završena osnovna škola	0	0%
	Završena dvogodišnja ili trogodišnja srednja škola	0	0%
	Završena četverogodišnja srednja škola	10	18,9%
	Završen stručni ili sveučilišni preddiplomski studij	12	22,6%
	Završen specijalistički stručni ili sveučilišni diplomski studij/integrirani preddiplomski i diplomski sveučilišni studij	27	50,9%
	Završen poslijediplomski specijalistički studij	1	1,9%
	Završen poslijediplomski znanstveni magistarski studij	1	1,9%
	Završen sveučilišni poslijediplomski doktorski studij	2	3,8%
Zanimanje	Učenik/ca	0	0%
	Student/ica	5	9,4%
	Zaposlen/a na određeno vrijeme	5	9,4%
	Zaposlen/a u stalnom radnom odnosu/na neodređeno vrijeme	39	73,6%
	Kućanica/domaćica	1	1,9%
	Nezaposlen/a	2	3,8%
	Umirovljenik/ca	0	0%
	Ostalo: honorarni posao	1	1,9%

Izvor: izrada autora

Ispitanici su uglavnom bili populacija s završenim specijalističkim stručnim ili sveučilišnim diplomskim studijem/integriranim preddiplomskim i diplomskim sveučilišnim studijem, u postotku od 50,9% ispitanika, 22,6% ispitanika sudjelovalo je s završenim stručnim ili sveučilišnim preddiplomskim studijem, 18,9% ispitanika bilo je s završenom četverogodišnjom srednjom školom. Velika većina ispitanika, čak njih 73,6% nalazi se u stalnom radnom odnosu na neodređeno vrijeme, dok je 94% ispitanika bilo u radnom odnosu na određeno vrijeme, također kao i studenata. U istraživanju su sudjelovale dvije nezaposlene osobe te jedna kućanica/domaćica, dok je 1 osoba navela da se bavi honorarnim poslom.

Rezultati istraživanja, prema demografskim karakteristikama promatranih kontrolnih varijabli prikazani su u Tablici 1.

Slika 3 prikazuje utjecaj marketinških sadržaja i ponuda u digitalnom okruženju na ponašanje ispitanika prilikom kupnje, donošenja odluke o kupnji te pokazuje da li su ispitanici bili potaknuti na impulzivnu kupnju. Pitanja koja su postavljena ispitanicima, a rezultati su prikazani Slikom 3 nalaze se u nastavku:

- Ima li marketinški sadržaj u digitalnom okruženju utjecaja na Vaše ponašanje prilikom kupnje?
- Potiče li Vas marketinški sadržaj u digitalnom okruženju na kupnju?
- Jeste li pod utjecajem sveprisutnog marketinškog sadržaja u digitalnom okruženju bili potaknuti na impulzivnu kupnju?

Slika 3. Utjecaj marketinških sadržaja i ponuda u digitalnom okruženju na ponašanje potrošača, odluku o kupnji i izazivanje impulzivne kupnje

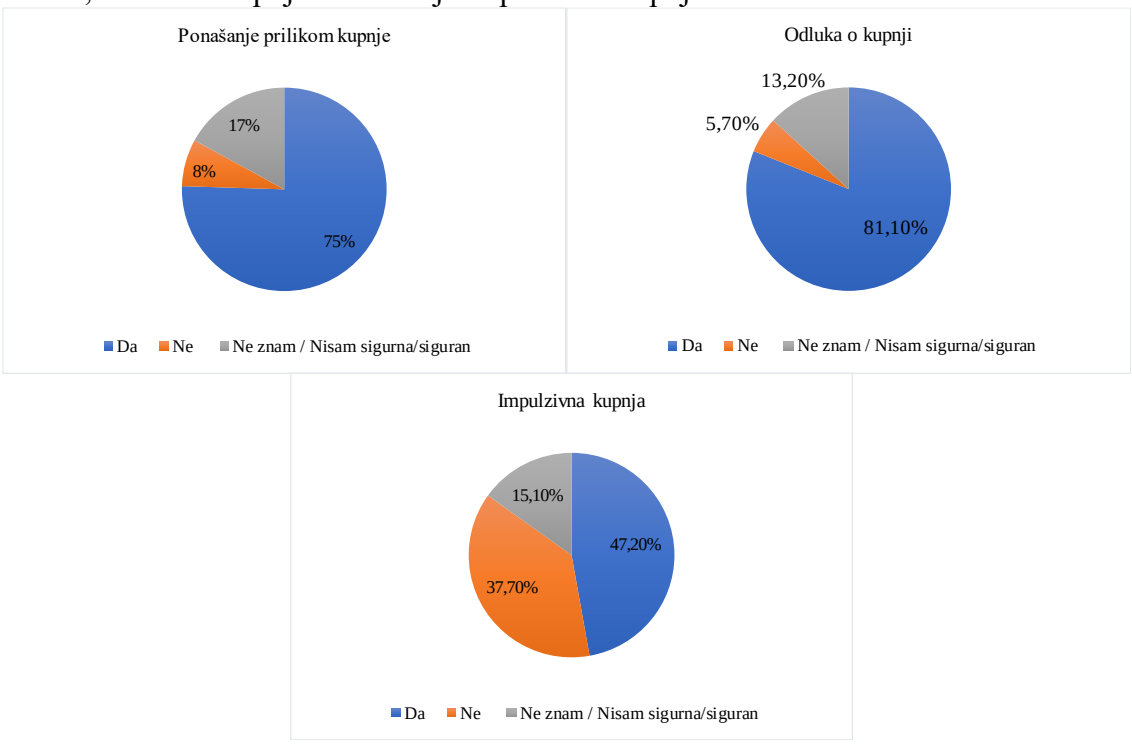

Izvor: izrada autora

Čak 75% ispitanika istaknulo je da marketinški sadržaji i ponude u digitalnom okruženju imaju utjecaj na njihovo ponašanje prilikom kupnje, dok samo njih 8% ističe da utjecaja nema. Ostatak ispitanika nije siguran postoji li utjecaj na ponašanje prilikom kupnje. Veliki broj ispitanika, njih 81,10% istaknulo je da su ih marketinški sadržaji i ponude u digitalnom okruženju potaknuli na kupnju, a kod njih 47,20% došlo je do impulzivne kupovine.

U nastavku su prikazana pitanja postavljena ispitanicima vezana uz praćenost, relevantnost, utjecaj i zanimljivost marketinških sadržaja:

- Koje marketinške sadržaje i ponude najviše pratite u digitalnom okruženju?
- Koje marketinške sadržaje i ponude u digitalnom okruženju smatrate relevantnima?
- Koji marketinški sadržaj i ponude u digitalnom okruženju imaju najviše utjecaja na vašu odluku o kupnji?
- Koji marketinški sadržaj i ponude u digitalnom okruženju su vam najzanimljiviji?

Slika 4. Praćenost, relevantnost, utjecaj na odluku o kupnji i zanimljivost marketinških sadržaja i ponuda u digitalnom okruženju

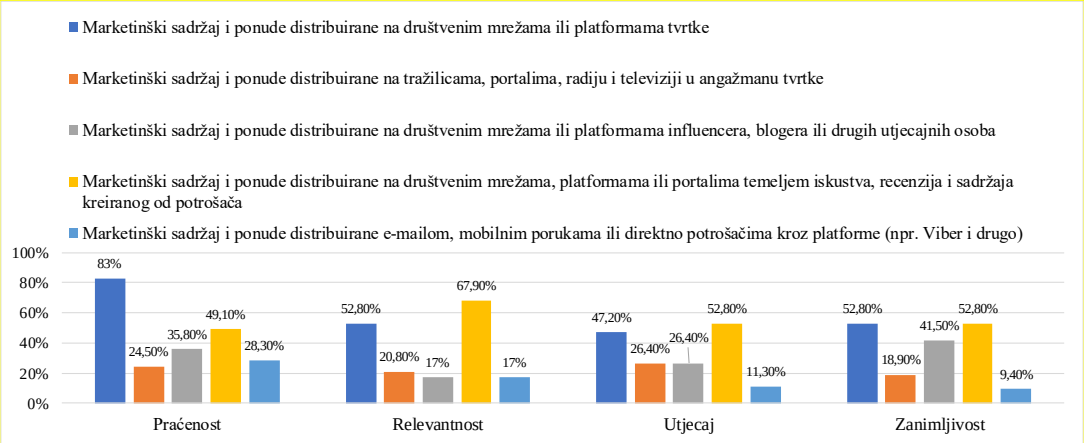

Izvor: izrada autora

Ispitanici su istaknuli da najviše prate marketinške sadržaje i ponude distribuirane na društvenim mrežama i platformama tvrtke (njih 83%) te sadržaje i ponude distribuirane na društvenim mrežama, platformama ili portalima temeljem iskustva, recenzija i sadržaja kreiranog od potrošača (49,10%). Najmanje su praćeni marketinški sadržaji i ponude distribuirani na tražilicama, portalima, radiju i televiziji u angažmanu tvrtke te samo 24,50% ispitanika prati takve sadržaje (Slika 4). Ispitanici najrelevantnijim smatraju sadržaje i ponude kreirane temeljem iskustva i recenzija potrošača (njih 67,90%) i direktno od tvrtki (njih 52,80%). Najmanji postotak ispitanika, tek njih 17%, smatra da su sadržaji i ponude distribuirane od strane influencera, blogera i drugih utjecajnih osoba te distribuirani e-mailom, mobilnim porukama ili direktno potrošačima kroz platforme (npr. Viber i drugo) relevantni. Ispitanici su iskazali da najveći utjecaj na donošenje odluke o kupnji imaju također sadržaji i ponude dostupni temeljem iskustva, recenzija i sadržaja kreiranog od potrošača na društvenim mrežama, platformama ili portalima (52,80%) te sadržaji i ponude dostupni na društvenim mrežama i platformama tvrtke (47,20%). Najmanji utjecaj na ispitanike imaju sadržaji i ponude dostupne e-mailom, preko mobilnih poruka ili platformi (za 11,30% ispitanika). Ova vrsta sadržaja ili ponuda, tek 9,40% ispitanika izdvojilo je kao zanimljivim, što znači da ova vrsta sadržaja zapravo budi najmanji interes kod ispitanika. Ispitanicima su zanimljivi sadržaji i ponude kreirane od potrošača (za 52,80% ispitanika), tvrtki (za 52,80% ispitanika) i influencera (za 41,50% ispitanika).

Slika 5 pokazuje prisutne osjećaje kod ispitanika prilikom i nakon kupnje. Vidljivo je da su kod većine ispitanika prisutni pozitivni osjećaji, prilikom kupnje za čak 67,90% te nakon kupnje za 62,30% ispitanika. Negativni osjećaji prisutni su tek kod 5,70% ispitanika prilikom i nakon kupnje, dok kod dijela ispitanika nisu prisutni nikakvih osjećaji prilikom kupnje (za 26,40% ispitanika) i nakon kupnje (32,10% ispitanika).

Slika 5. Osjećaji potrošača prilikom i nakon kupnje

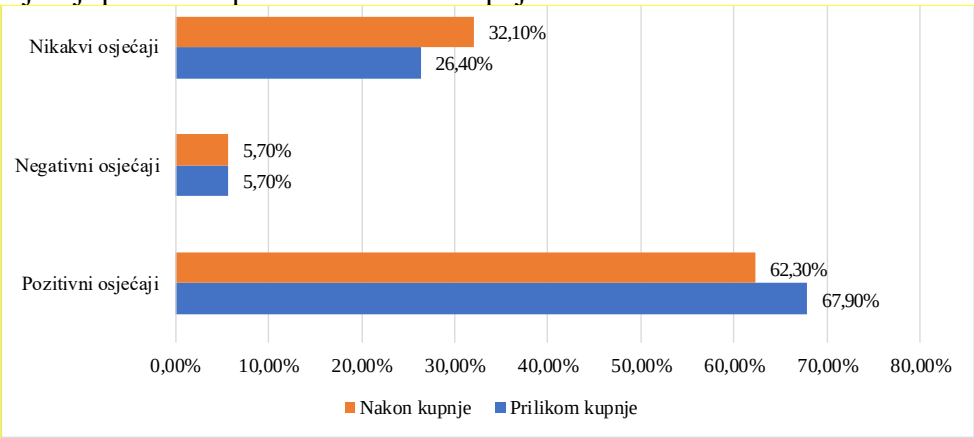

Izvor: izrada autora

Slika 6 pokazuje da za većinu ispitanika proces kupnje predstavlja zadovoljstvo i uzbuđenje. Naime, 35,80% ispitanika osjeća zadovoljstvo prilikom kupnje, a ono se smanjuje nakon kupnje, što je potvrdilo 20,80% ispitanika. Uzbuđenje je podjednako prilikom i nakon kupnje, za 20,80% ispitanika, odnosno njih 18,90%. Ipak, čini se da prisutnost pozitivnih osjećaja opada nakon kupnje jer su neki od ispitanika izostavili prisutnost pozitivnih osjećaja prilikom, odnosno nakon kupnje. Njih 15,10% naveli su da kod njih nisu prisutni pozitivni osjećaji prilikom kupnje, odnosno kod 22.60 % ispitanika nakon kupnje. Kod manjeg broja ispitanika javljaju se osjećaji poput uzbudljivosti, sreće, smirenosti, opuštenosti i ushićenosti.

Slika 6. Prisutni pozitivni osjećaji prilikom i nakon kupnje

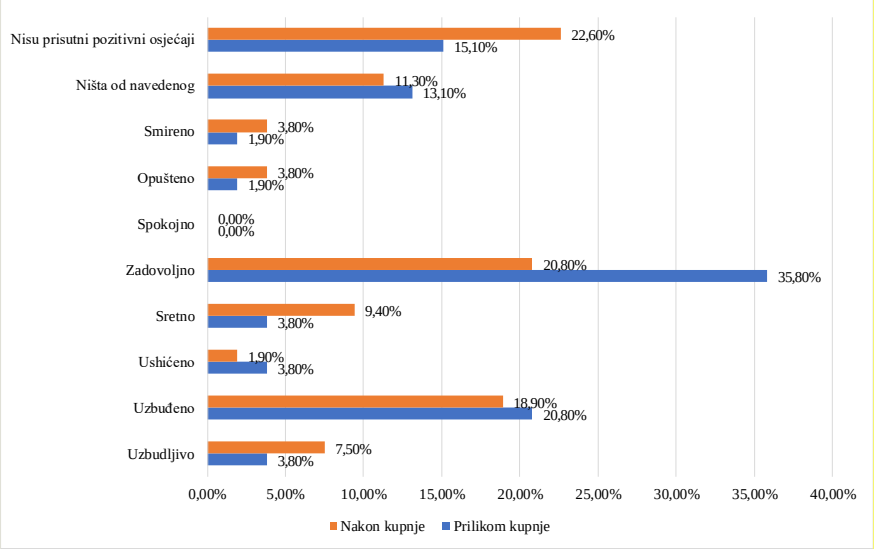

Izvor: izrada autora

Slika 7 pokazuje kako kod velikog broja ispitanika (otprilike njih 50%) nisu prisutni negativni osjećaji prilikom i nakon kupnje. Također, dio ispitanika izjasnio se kako kod njih nisu prisutni navedeni negativni osjećaji. Tek mali postotak ispitanika izdvojio je neke od negativnih osjećaja, poput zabrinutosti, tuge, potištenosti, napetosti i uzrujanosti, prisutnima prilikom i nakon kupnje.

Slika 7. Prisutni negativni osjećaji prilikom i nakon kupnje

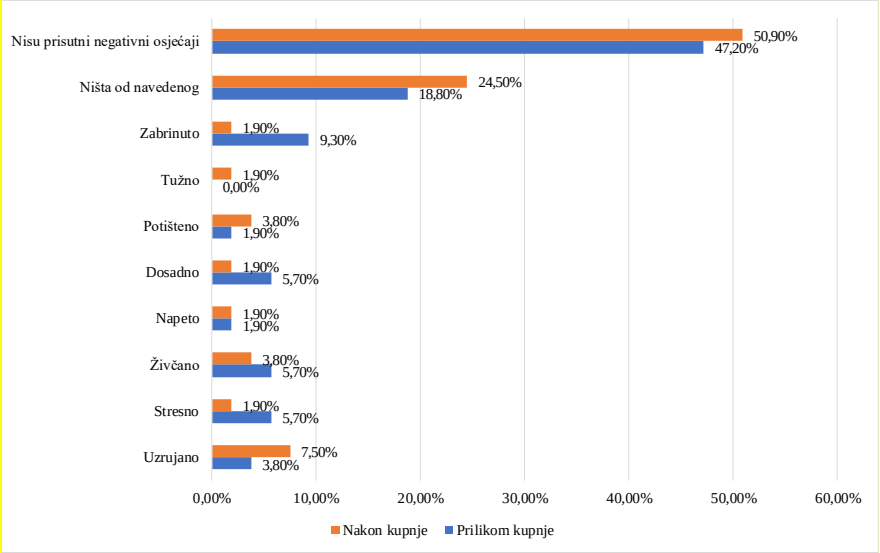

Izvor: izrada autora

5. RASPRAVA I ZAKLJUČAK

Digitalne tehnologije omogućile su da marketinški sadržaji i ponude pronalaze put do potencijalnih kupaca lakše nego ikad. Distributivni kanali putem kojih se dijeli sadržaj i ponude, poput platformi, društvenih mreža, mobilnih poruka i drugi, omogućuju da se to odvija na efektivan i korisnicima primamljiv način. U marketinške aktivnosti više nisu uključene samo tvrtke i marketinški stručnjaci, već akteri postaju influenceri, utjecajne osobe, pa čak i sami potrošači. Primamljivi digitalni sadržaj tjera ljude da gotovo svaki slobodan trenutak koriste za praćenje aktualnosti na ekranima pametnih uređaja. Ljudi su sve više podložni brojnim sadržajima gdje su im direktno ili indirektno dostupni različiti privlačni proizvodi i usluge što budi njihov interes i želju za korištenjem i kupnjom istih. Stoga, ponašanje potrošača, pa tako i donošenje odluke o kupnji, mogu biti rezultat primamljivih sadržaja, no to može imati utjecaj na osjećaje potrošača.

Istraživanjem je pokazalo da marketinški sadržaji i ponude u digitalnom okruženju utječu na ponašanje potrošača i donošenje odluke o kupnji, a kod nekih kupaca dovode do impulzivne kupovine. Time su potvrđeni navodi iz literature da sveprisutni marketinški sadržaji mogu značajno utjecati na potrošače i potaknuti njihovo ponašanje u željenom smjeru.

Istraživanje je pokazalo da najveći utjecaj na donošenje odluke o kupnji imaju sadržaji i ponude distribuirane od tvrtki ili potrošača temeljem njihovih iskustva i recenzija. Povjerenje u sadržaj i ponude dijeljene od influencera, blogera ili utjecajnih osoba je narušeno te sve više ispitanika smatra da oni više nemaju takav utjecaj na njihovo ponašanje iako su njihovi sadržaji zanimljivi. Veći dio ispitanika sadržaje koje kreiraju influenceri ne smatra relevantnima. To potvrđuje tvrdnje istaknute u literaturi gdje je navedeno da sve više potrošača ispituje autentičnost preporuka influencera. Potrošači imaju više povjerenja, a samim time, i svoju odluku o kupnji, donose temeljem iskustva i recenzija anonimnih pojedinaca, a također imaju povjerenja u poslovnu zajednicu.

Iako je temeljem kvalitativnog istraživanja utvrđeno da su moguće potencijalne razlike u osjećajima prilikom i nakon kupovine, istraživanje nije to potvrdilo. Naime, pozitivno osjećaji

prisutni su kod većine ispitanika prilikom kupnje, a također, pozitivni osjećaji ostali su prisutni i nakon kupnje. Neznatan je broj ispitanika kod kojih su prisutni negativni osjećaji. Time je utvrđeno da se ispitanici ne osjećaju negativno ili loše zbog potrošnje pod utjecajem marketinških sadržaja i ponuda u digitalnom okruženju, već to pozitivno utječe na njih same.

Od pozitivnih osjećaja prilikom i nakon kupnje kod otprilike jedne trećine ispitanika zabilježeni su osjećaji poput zadovoljstva i uzbuđenosti. Zanimljivo je kako se u literaturi kupnja često povezuje s osjećajima opuštenosti, smirenosti i sreće, a tek je mali broj ispitanika je ove osjećaje izdvojio kao prisutne prilikom i nakon kupnje. Kod većine ispitanika nisu prisutni negativni osjećaji prilikom i nakon kupnje, odnosno nisu prisutni navedeni negativni osjećaji. Tek mali broj ispitanika ističe zabrinutost, tugu, potištenost ili uzrujanost, a dok literatura ipak naglašava potencijalno moguće negativne osjećaje zbog impulzivne potrošnje, bespotrebne kupovine i drugo.

Marketinški sadržaj u digitalnom okruženju jednostavno pronalazi put do kupaca i utječe na njihovu odluku o kupnji. Potencijalni kupci imaju pristup sadržajima s vrlo primamljivim ponudama što ih potiče na kupnju i dovodi do povećane potrošnje. Svijest o razumnom razmatranju marketinških sadržaja i ponude na tržištu postaje sve važnija u digitalnom okruženju. Također, psihološki utjecaj koji imaju marketinški sadržaji može dovesti do pozitivnih, ali i negativnih afekata potrošnje te imati utjecaj na osjećaje potrošača.

6. OGRANIČENJA I ISTRAŽIVAČKI RAD U BUDUĆEM PERIODU

Provedeno istraživanje pružilo je uvid u utjecaj marketinških sadržaja na ponašanje potrošača i njihovu odluku o kupnji te osjećaje izazvane potrošnjom, no u istraživanju je sudjelovao mali uzorak ispitanika, stoga su neki opsežniji i jasniji zaključci izostali. Naime, može se jasno utvrditi da marketinški sadržaji u digitalnom okruženju utječu na potrošače i da se posebno ističu sadržaji kreirani temeljem iskustva i recenzija potrošača, kao i sadržaj tvrtki, no ipak moguće je da su ispitanici podložni i nekim drugim potencijalnim kanalima distribucije marketinškog sadržaja. U analizi osjećaja koji su prisutni kod potrošača prilikom i nakon potrošnje ne postoji značajnih razlika. Štoviše, većina ispitanika navela je kako su prisutni pozitivni osjećaji, dok su negativni zanemareni. Literatura ima oprečna razmišljanja vezano uz ove rezultate, s obzirom da povećana potrošnja, impulzivna kupnja i kupnja nepotrebnih stvari može izazvati negativne osjećaje kod potrošača.

Provedeno istraživanje bit će prošireno na način da će biti napravljena analiza koliko često su potrošači u prisustvu određenih marketinških sadržaja te koliko učestalo pristaju na ponude istih. Buduće istraživanje uključit će veći broj ispitanika kako bi se ispitao utjecaj marketinških sadržaja u digitalnom okruženju na povećanu potrošnju, impulzivnu kupnju i kupnju nepotrebnih stvari te utjecaj istog na osjećaje potrošača.

REFERENCE

[1] Ahmad, N. S., & Rosli, R. (2023). The Role of Social Media Content Marketing (SMCM) as a Digital Marketing Strategy towards the Internal Factors of Consumer Behavior among the Millennials. Asia-Pacific Journal of Management and Technology (AJMT), 4(1), Article 1. https://doi.org/10.46977/apjmt.2023.v04i01.005

[2] Alkharabsheh, O. H. M., & Zhen, B. H. (2021). The Impact of Content Marketing, Social Media Marketing and Online Convenience on Consumer Buying Decision Process. CoMBInES - Conference on Management, Business, Innovation, Education and Social Sciences, 1(1), Article 1.

[3] Anderson, G. (2020, May 13). Americans are shopping more impulsively online—RetailWire. https://retailwire.com/discussion/americans-are-shopping-more-impulsively-online/

[4] Barrett, L., & Russell, J. (1998). Independence and Bipolarity in the Structure of Current Affect. Journal of Personality and Social Psychology, 74, 967–984. https://doi.org/10.1037/0022-3514.74.4.967

[5] Barta, S., Gurrea, R., & Flavián, C. (2021). The role of flow consciousness in consumer regret. Internet Research, 32(3), 875–896. https://doi.org/10.1108/INTR-08-2020-0482

[6] Cinar, D. (2020). The Effect of Consumer Emotions on Online Purchasing Behavior. In Tools and Techniques for Implementing International E-Trading Tactics for Competitive Advantage (pp. 221–241). IGI Global. https://doi.org/10.4018/978-1-7998-0035-4.ch011

[7] Dobrinić, D. (2023). Marketing—Od papirusa do chatbota. Poslovna knjižara UM. https://knjizaraum.hr/knjiga/marketing-od-papirusa-do-chatbota/

[8] Feldman Barrett, L., & Russell, J. A. (1998). Independence and bipolarity in the structure of current affect. Journal of Personality and Social Psychology, 74(4), 967–984. https://doi.org/10.1037/0022-3514.74.4.967

[9] Figueiredo, F., Gonçalves, M. J. A., & Teixeira, S. (2021). Information Technology Adoption on Digital Marketing: A Literature Review. Informatics, 8(4), Article 4. https://doi.org/10.3390/informatics8040074

[10] Lim, S. H., Lee, S., & Kim, D. J. (2017). Is Online Consumers' Impulsive Buying Beneficial for E-Commerce Companies? An Empirical Investigation of Online Consumers' Past Impulsive Buying Behaviors. Information Systems Management, 34(1), 85–100. https://doi.org/10.1080/10580530.2017.1254458

[11] Lou, C. (2022). Social Media Influencers and Followers: Theorization of a Trans-Parasocial Relation and Explication of Its Implications for Influencer Advertising. Journal of Advertising, 51(1), 4–21. https://doi.org/10.1080/00913367.2021.1880345

[12] Markets, R. and. (2022, September 28). Global Digital Advertising and Marketing Market to Reach $786.2 Billion by 2026 at a CAGR of 13.9%. GlobeNewswire News Room. https://www.globenewswire.com/en/news-release/2022/09/28/2524217/28124/en/Global-Digital-Advertising-and-Marketing-Market-to-Reach-786-2-Billion-by-2026-at-a-CAGR-of-13-9.html

[13] Matin, A., Khoshtaria, T., & Todua, N. (2022). The Impact of Social Media Influencers on Brand Awareness, Image and Trust in their Sponsored Content: An Empirical Study from Georgian Social Media Users. International Journal of Marketing, Communication and New Media, 10, 88–114. https://doi.org/10.54663/2182-9306.2022.v10.n18.88-114

[14] Mendoza-Moreno, V. N., & Turriate-Guzmán, A. M. (2022). Social Media Influencers and Their Impact on Consumer Behavior: A Systematic Review of the Scientific Literature. 2022 IEEE 5th International Conference on Electronics and Communication Engineering (ICECE), 94–98. https://doi.org/10.1109/ICECE56287.2022.10048604

[15] Munsch, A. (2021). Millennial and generation Z digital marketing communication and advertising effectiveness: A qualitative exploration. Journal of Global Scholars of Marketing Science, 31(1), 10–29. https://doi.org/10.1080/21639159.2020.1808812

[16] Niven, K., & Miles, E. (2013). Affect Arousal. In M. D. Gellman & J. R. Turner (Eds.), Encyclopedia of Behavioral Medicine (pp. 50–52). Springer. https://doi.org/10.1007/978-1-4419-1005-9_1089

[17] Plessis, C. du. (2022). A Scoping Review of the Effect of Content Marketing on Online Consumer Behavior. SAGE Open, 12(2), 21582440221093040–21582440221093040.
[18] Polanco-Diges, L., & Debasa, F. (2020). The Use of Digital Marketing Strategies in the Sharing Economy: A Literature Review. Journal of Spatial and Organizational Dynamics, VIII.
[19] Posner, J., Russell, J. A., & Peterson, B. S. (2005). The circumplex model of affect: An integrative approach to affective neuroscience, cognitive development, and psychopathology. Development and Psychopathology, 17(3), 715–734. https://doi.org/10.1017/S0954579405050340
[20] Quora. (n.d.). What are the negative aspects of content marketing? Retrieved September 30, 2023, from https://www.quora.com/What-are-the-negative-aspects-of-content-marketing
[21] Saura, J., Reyes-Menendez, A., Matos, N., Correia, M., & Palos-Sanchez, P. (2020). Consumer Behavior in the Digital Age. Journal of Spatial and Organizational Dynamics, 8, 190–194.
[22] Tong, X., Chen, Y., Zhou, S., & Yang, S. (2022). How background visual complexity influences purchase intention in live streaming: The mediating role of emotion and the moderating role of gender. Journal of Retailing and Consumer Services, 67, 103031. https://doi.org/10.1016/j.jretconser.2022.103031
[23] Wang, M., Sun, L.-L., & Hou, J.-D. (2021). How Emotional Interaction Affects Purchase Intention in Social Commerce: The Role of Perceived Usefulness and Product Type . Psychology Research and Behavior Management, 14, 467–481. https://doi.org/10.2147/PRBM.S301286
[24] Yarwood, M. (n.d.). Russell's (1980) Circumplex Models. Retrieved August 21, 2023, from https://psu.pb.unizin.org/psych425/chapter/circumplex-models/

Original scientific paper / Izvorni znanstveni rad

GENDER DIFFERENCES IN GENERATION Z IN CONTEXT OF TRADITIONAL SOCIAL MEDIA USAGE

MATEA MATIĆ ŠOŠIĆ
University of Dubrovnik
Department of Economics and Business Economics
Lapadska obala 7, 20000 Dubrovnik, Croatia
matea.matic@unidu.hr

ABSTRACT

Social media play a dynamic role in user's life style by removing communication barriers and become a noticeable place for social interactions. Therefore, social media with its interactive features provide users opportunities to engage with other users and companies. This study investigates the gender difference of Generation Z in relation to features of social media usage. Also, this study explores the relation between purchase intentions and company created social media content, purchase recommendations, sharing the purchase experience in Generation Z. The research instrument was a questionnaire, and data were collected through social media platforms using Google forms. Descriptive statistics, Spearman correlation coefficients and nonparametric statistics (Mann-Whitney U Test) were used to achieve the objective of this study. The research sample consisted of 162 social media users of Generation Z. The results reveal that there is a significant difference between the features of social media usage and gender of Generation Z. Also, research results found statistical significant relation between purchase intentions and company created social media content, sharing information about past purchase experience and encouraging other users to make purchase in social media. At the end of the paper, the author discusses the results, along with implications, limitations and recommended future research directions. This paper contributes on the field of theory to better understanding of the gender differences in social media and also it has practical implications to online retailers and marketing experts in order to highlighted barriers that are specific for purchase behaviour in social media based on gender awareness.

KEYWORDS: social media, generation z, purchase intention

1. INTRODUCTION

Social media usage has grown exponentially in recent year and it has become an integral part of consumer lifestyle [Muhammad et al. 2017]. Today, consumers are increasingly using social media sites to search for information and turning away from traditional media, such as television, radio, and magazines [Mangold and Faulds, 2009]. Social media has become an essential tool of the younger population, especially generation Z. Social media allows people to connect, communicate, discuss, and interact through social media and offer them unique opportunity to fulfil their needs for additional information or products. Therefore, social media is platforms and tools that people use to share opinions and experiences including photos, videos, music, insights and perceptions with each other [Turban, 2009]. On the other hand, social media also provide required, different values to companies, such as improved brand

awareness [De Vries et al., 2012], enabling faster word-of-mouth communication [Chen et al. 2011], increasing sales [Agnihotri et al., 2012], sharing information in a business context [Lu and Hsiao 2010] and creating strong social support for consumers [Ali, 2011]. These valuable data gathered on social media provides company useful information about consumer awareness towards their products and reputation. Therefore, this information offer in social media could help the companies identify how consumers perceived them and their products [Asamoah, 2019] in order to establish strong relation and gain strong competitive advantage.

The special characteristics of social media platforms and the unique opportunities they provide for the consumers and companies, has made the study of consumer purchase behavior more complex [Arenas-Gaitán et al., 2019]. Understanding and determine users purchase behavior on social media is significant important for companies and marketers in order to allows them to communicate more effectively with potential and present consumer. Especially, the social media usage is being increasingly embraced by Generation Z. This generation have extensive internet access and online presence and, therefore, understanding their social media usage could be significant to marketers and companies. In addition, companies are trying to take advantage of increasing trend of customers depending on social media particularly for their purchases. Therefore, the aim of this study is to investigate the gender difference of generation Z in relation to features of social media usage. Also, this study explores the relation between purchase intentions and company created social media content, purchase recommendations, sharing the purchase experience in Generation Z.

The paper is organized as follows. Section 2 is literature review, section 3 explains the methodologies used in the study followed by presentation of research results and analysis in section 4. Finally, the paper is concluded with a discussion, limitation of the study and description of future recommendation in Section 5.

2. LITERATURE REVIEW

Nowadays, social media is an effective and convenient platform. Social media are increasingly used for commercial purposes [Vanani and Majidian, 2019] and extensive growth of social media usage often define consumer purchase behavior [Wang et al. 2019; Khajeheian and Ebrahimi, 2020]. Today, users in social media spending more time searching and providing helpful information, which mostly determine their purchase intentions. Research shows that social media can influence on consumers' perceptions, attitudes, and intentions [Narangajavana et al., 2017; Dwivedi et al., 2021].

Social media has influenced consumer behavior from information acquisition to post-purchase behavior [Mangold and Faulds, 2009]. Users view social media platforms as an additional service or sales channel, where they can engage with the company. Also they are allowed to create user generated content [Moghadamzadeh et al., 2020] and share them in social media platforms in order to provide helpful and useful information to the other users. They often use different perspectives such as data sharing and social media usage [Muhammad et al., 2022] because they are concerns about their privacy or risky purchase decision. In order to reduce purchase risk, consumers rely on product ratings, feedback, and comments about the product [Aladwani, 2018; Xu et al., 2020]. Sharma and Rehman [2012] suggested that positive or negative review or comments about a product posted on the social media has significant influence on consumers purchase behaviour. On the other hand, social media usage encourage company to create some type of engagement and relationship with their potential customers

[Park et al., 2021]. Social media increases customer's purchase intentions, and also increase companies' sales and long-term relationships with users [Trawnih et al., 2021]. Many research confirmed that word of mouth has positive impact on purchase intention in social media [Yusuf et al., 2018; Wang and Herrando, 2019; Park et al., 2021]. Therefore, companies could take advantage of social media in distributing comprehensive information, influencing on user's attitudes and opinions, increasing their reputation and generating positive word-of-mouth [Song et al., 2021]. These interactions provide different benefits and values for both, companies and users in social media environment.

Many young people especially Generation Z use social media platforms on a daily basis [Digital 2022 Global Overview report]. The Z generation are an attractive segment especially for social media marketing activities since they are always connected to their social media [Flynn et al., 2016]. Social media usage is being increasingly embraced by Generation Z [Kaplan and Haenlein, 2010]. They mostly use for conversation and communication with their friends and groups but also use for purchasing decision process. The Generation Z have better awareness of products and services, are efficient in searching and providing information on the social media platform, enjoy purchasing, pay attention to advertising, and they are often seeking and use different promotions on social media.

Gender differences have been shown to occur in the social media and have strong effects on purchase behaviour [Raacke and Bonds-Raacke, 2008; McAndrew and Jeong, 2012;], but results are different. Some studies find that women are more active social media users than men and show different type of behaviours [Sheldon and Bryant, 2016; Khan, 2017]. Research reveals that young women are more likely to use social media to maintain existing relations, or for informational and education gratifications, while young men prefer to use social media to meet new people and socialize [Kircaburun et al., 2020]. Kian, et al., 2017 find that men have stronger purchase intention in social media websites than women. However, women users as compared to men are more influenced with eWOM are when buying in social media (Kim et al., 2011). Also, women are tending to less risk taking and rely on online reviews before buying the products in social media [Sohaib et al., 2018]. They have higher levels of concerns about tangible rewards and are more likely to take advantage of promotions and sales when shopping in social media platform than male users [Venkatesh et al., 2012]. According to Zhang et al. [2013], women are more likely than men to express their opinions and emotions and probably be more inclined to posted review or comments about their purchase experience. Furthermore, men and women share different types of topics on social media such as Facebook. For example, men like to share information about their favourite team and sports events, while women like to share a variety of topics such as their lifestyle, talking about their children and their personal hobbies [Lin and Wang, 2020].

3. METHODOLOGY

This study investigates the gender difference of generation Z in relation to features of social media usage. Also, this study explores the relation between purchase intentions and firm-created social media content, purchase recommendations, sharing the purchase experience in Generation Z. To achieve the objectives of the study, a questionnaire was developed based on the results of the literature review. A questionnaire was designed to collect the necessary data from a convenience sample of consumers who have already used social media platforms. The research sample consisted of 162 social media users of Generation Z. Generation Z is identified as individuals who were born in the mid-1990s; some studies mark the beginning of this

generation as the year 1995, while others consider it 1997–1998, arguably ending between 2012 and 2018. This study includes social media users born between 1995 and 2010 [Suderman, 2016, Rosenblant, Ramirez, Oulopis, 2016]. Data collection was done by distributing questionnaires to respondents via Google forms. shared on social media such as Facebook and Instagram. The participants who are younger than 18 provided informed consent of adults, prior to accessing the surveys.

The required data was collected between July 2021 and October 2021. A convenience sampling approach was used for data collection. The survey questionnaire consisted of two sections. The first section included questions, "How often do you use social media" and Using social media company achieve" measured with an ordinal scale with closed questions. The second part included statements about purchase intentions, firm-created social media content, purchase recommendations and sharing the purchase experience. The statements were measured using a 5-point Likert scale ranging from 1 to 5, with respondents expressing their level of agreement or disagreement with the statement (1=completely disagree, 5=strongly agree). In addition, the questionnaire included demographic characteristics such as gender, age, education level, and monthly income of the respondents

4. RESEARCH RESULTS

The Mann-Whitney U Test is a non-parametric statistical technique used in statistics to examine differences between two independent groups on a continuous or ordinal scale. The reasons why the Mann-Whitney U test was use because the independent variable, gender consists of more than 2 groups gender: "male" and "female"). The Mann– Whitney U test was used for statistical analysis of the data ($\alpha = 0.05$). To get the *U* statistic, instead of using means, we use ranks by ordering the scores from both groups from smallest to largest, keeping track of which group each score came from, then adding up the ranks for the scores from each group [Emerson, 2023.]. The test results of mean ranks for every statements according to gender are presented in the following Table 1.

Table 1. Mean ranks

	GENDER	N	MEAN RANK	SUM OF RANKS
I intend to make purchases on social media in the future.	Male	61	72,06	4395,50
	Female	101	87,20	8807,50
	Total	162		
Purchasing via social media is in trend.	Male	61	68,16	4157,50
	Female	101	89,56	9045,50
	Total	162		
Reviews on social media helps in making purchase decisions.	Male	61	67,48	4116,50
	Female	101	89,97	9086,50
	Total	162		
Social media are a good additional	Male	61	71,46	4359,00

channel of sales and advertising for the company.	Female	101	87,56	8844,00
	Total	162		
I am searching for information about products advertised on social media.	Male	61	71,42	4356,50
	Female	101	87,59	8846,50
	Total	162		

Source: Research findings (N=162)

The Mann-Whitney U test to assess the significance of differences between respondents in terms of demographic characteristic such as gender. Additional confirmation of the results has been obtained by Mann Whitney test with significance below α=0,05 in Table 2,3,4,5 and 6. The following table shows the Mann Whitney test result for purchase intentions considering the gender of Generation Z.

Table 2. Mann Whitney U test - gender of Generation Z and purchase intentions

	Purchase intentions
Mann-Whitney U	2504,500
Wilcoxon W	4395,500
Z	-2,082
Asymp. Sig. (2-tailed)	,037

Grouping Variable: GENDER
Source: Research findings (N=162)

Table 1 provide data on the calculated z-values and the approximately calculated statistical significance of differences between the crossed variables Since the significance for purchase intentions is less than 0.05, exactly 0.037, it can be confirmed that there is a statistically significant difference in the purchase intentions with regard to the gender of Generation Z. Introduction of gender variable into further analysis indicates that female respondents are more inclined to make purchase in social media than men. This is confirmed by the results from table 1 where the rank for women is 8807,50 and for men is 4395,50. The next table shows the Mann Whitney test result for purchasing via social media is in trend considering the gender of the respondent.

Table 3. Mann Whitney U test - gender of Generation Z and purchasing via social media is in trend.

	Purchasing via social media is in trend.
Mann-Whitney U	2266,500
Wilcoxon W	4157,500
Z	-3,045
Asymp. Sig. (2-tailed)	,002

Grouping Variable: GENDER
Source: Research findings (N=162)

The existence of significant statistical difference in the purchasing via social media is in trend per gender of Generation Z was confirmed by Mann Whitney test, shown in the Table 3, the significance being below α=0,05. When analysing the gender difference, it is noticeable that female respondents are more likely to agree with the statement in relation to the male

respondents, since the rank for female is 9045,50 and for men 4157,50 (Table 1). Research results suggest that female respondents of Generation Z consider social media as convenient and trendy place for purchasing. Most likely, female respondents believe that shopping through social media will provide more suitable and comprehensive information that can help in purchasing decision making. The results of Mann Whitney test for variable gender of Generation Z and reviews on social media helps in making purchase decisions are present in the Table 4.

Table 4. Mann Whitney U test - gender of Generation Z and reviews on social media helps in making purchase decisions

	Reviews on social media helps in making purchase decisions.
Mann-Whitney U	2225,500
Wilcoxon W	4116,500
Z	-3,205
Asymp. Sig. (2-tailed)	,001

Grouping Variable: GENDER
Source: Research findings (N=162)

Table 4 shows the Mann Whitney test result for reviews on social media helps in making purchase decisions considering the gender of Generation Z. Since the significance for reviews on social media helps in making purchase decisions is less than 0.05 and is 0.001, it can be confirmed that there is a statistically significant difference between reviews on social media that helps in making purchase decisions with regard to the gender of Generation Z. Table 1 shows the ranks of reviews on social media helps in making purchase decisions with regard to gender of the respondent indicating that women are more likely to search for review before making a purchase decision since the rank is 9086,5, and for men it is 4116,50. Next table show result of Mann Whitney test between gender of Generation Z and social media are a good additional channel of sales and advertising for the company.

Table 5. Mann Whitney U test - gender of Generation Z and social media are a good additional channel of sales and advertising for the company.

	Social media are a good additional channel of sales and advertising for the company.
Mann-Whitney U	2468,000
Wilcoxon W	4359,000
Z	-2,297
Asymp. Sig. (2-tailed)	,022

Grouping Variable: GENDER
Source: Research findings (N=162)

Table 5 indicates that there are statistically significant differences in attitudes of respondents to the said statements with respect to gender. The significance is 0.022, being less than α=0,05. Results shows that female respondents since the rank is 8844,00, are more prone to agree with the statement that a social media is a good additional channel of sales and advertising when compared with male respondents with rank of 4359,00. Female respondents consider social mead as efficient place where can get more timely information through advertisements. Also, they perceived social media as a potential place for making purchases more efficiently since they have direct communication with the preferred company. Mann Whitney U test between gender of Generation Z and searching for information about a product on social media are shown in Table 6.

Table 6. Mann Whitney U test - gender of Generation Z and searching for information about a product on social media

	Searching for information about a product on social media
Mann-Whitney U	2465,500
Wilcoxon W	4356,500
Z	-2,282
Asymp. Sig. (2-tailed)	,023

Grouping Variable: GENDER
Source: Research findings (N=162)

The results show that, there is a statistically significant difference in the mean score gender and searching for information about a product on social media (Mann–Whitney U = 2465,500, p = 0.023). The female respondents of Generation Z tend to rely more on the search of general information before purchasing the products via social media.

Regarding social media usage, as the Mann–Whitney results indicate, there is enough evidence to conclude that there are significant differences between the gender of Generation Z and 5 statements. Since all p-values are smaller than the significance level of 5%, there is a significant gender difference regarding every statement included in this paper. For every statements (Table 1), female respondents of Generation Z ranked higher than males. This demonstrates with respect to social media usage that female respondents are more inclined toward purchasing via social media and provide useful information about their purchase experience. Furthermore, female respondents will likely to talk about, recommend or purchase products on social media since they consider social media a useful advertising tool as well as an additional and potential point of sale. Table 7 shows the results of correlation matrix between purchase intentions and pre-purchase behaviour, number of reviews and intention to review.

Table 7. Correlation matrix between purchase intentions and company created social media content, sharing information about past purchase experience and encouraging other users to make purchase in social media

Spearman's rho	**Purchase intentions**
I would encourage my friends to purchase via social media.	665**
	,000
I would share the purchase experience via social media.	553**
	,000
The level of communication with companies via social media meets my expectations	464**
	,000

** Correlation is significant at 0,01
Source: Research findings (N=162)

Statistical analysis of data displayed in Table 7 found statistically significant, moderately strong but positive relation between purchase intentions and company created social media content, sharing information about past purchase experience as well as encouraging other users to make purchase in social media. Values of Spearman's correlation coefficient show statistically significant, moderately strong positive relation between purchase intentions and company created social media content. The result confirm that the users are satisfied with the company created social media content because it allows them to simply follow the latest news and trends that appear daily in social media. Also, the result indicate that users are satisfied with the communication because they can exchange information with the company in a very simple way in order to fulfil their needs. Such an approach allows users to develop strong individual relation

with the company and become potential loyal consumer in future. Further, statistical analysis presented in the table 7, show moderately strong but statistically significant, positive relationship between purchase intention and sharing information about past purchase experience. From the data shown in table 7 it can be seen that users will be willing to share the necessary information about their past purchase experiences and satisfaction with the products purchase via social media. Further analysis, show that there is a strong statistically significant, positive relationship between purchase intention and encouraging other users to make purchase in social media. The results suggested that users, based on their own positive purchase experiences, will encourage other users to buy a product they are satisfied with. Such a result indicates that e-WOM can have a significant impact on the purchase intentions of other users in future.

5. CONCLUSION

This study investigates the gender difference of generation Z in relation to features of social media usage. Also, explores the relation between purchase intentions and firm-created social media content, purchase recommendations, sharing the purchase experience in Generation Z. In context of results, female respondents of Generation Z ranked higher than males. Female respondents will likely to exchange information, recommend or purchase products on social media since they consider social media a useful advertising tool as well as an additional and potential point of sale. Further statistical analysis shows statistically significant, moderately strong but positive relation between purchase intentions and company created social media content, sharing information about past purchase experience as well as encouraging other users to make purchase in social media. The result confirm that the users are satisfied with the company created social media content because it enables them to simply follow the latest news and trends that appear daily in social media. Also, the result indicate that users are satisfied with the communication because they can exchange information with the company in a very simple way in order to fulfil their needs. Such approach allows users to develop strong individual relation with the company and become potential loyal consumer in future. Also, users will be willing to share the necessary information about their past purchase experiences and satisfaction with the products purchase via social media. They probably believe that sharing the crucial information can be useful for other users to helps them by reducing the perceived risk in purchase in order to make a right purchase decision. In addition, results recommended that users, based on their own positive purchase experiences, will encourage other users to buy a product they are satisfied with. Such a result indicates that e-WOM can have a significant impact on the purchase intentions of other users in future.

A deeper understanding of gender difference in social media can be helpful for both researchers and practitioners to gain better insights into consumer purchase behavior. Investigating gender differences in social media could benefit to companies in order to highlighted barriers that are specific for purchase behaviour in social media based on gender awareness.

The main limitation is that the study is based on non-probability convenience sampling, meaning that the sample is unlikely to be representative of the population being studied, have unbalanced sampling structure and small number of sample units. Limitation of this study is that it refers to only Z Generation users, which also limits the generalization of the research results. Considering the stated limitations, future research should consider to include other generation in sample and to include additional variables to this survey to gain a comprehensive insight into users' social media usage.

REFERENCES

[1] Agnihotri, R.; Kothandaraman, P.; Kashyap, R.; Singh, R. (2012). Bringing "social" into sales: The impact of salespeople's social media uses on service behaviors and value creation. Journal of Personal Selling & Sales Management, 32(3), pp 333-348, 2012.

[2] Aladwani, A. M. (2018). The Moderating Influence of Socially-Inspired Trust on the Connection Between Persuasive Governmental Social Media Quality and Success. In Trends and Advances in Information Systems and Technologies, 1(6), pp. 242-247. 2018.

[3] Ali, A. H. (2011). The power of social media in developing nations: New tools for closing the global digital divide and beyond. Harv. Hum. Rts. J., 24, 185, 2011.

[4] Arenas-Gaitán, J.; Sanz-Altamira, B.; Ramírez-Correa, P. E. (2019). Complexity of understanding consumer behavior from the marketing perspective. Complexity, pp. 1-3, 2019.

[5] Asamoah, K. (2019). E-governance in Africa's local governments: Do district assemblies in Ghana optimize the use of websites and social media? The Electronic Journal of Information Systems in Developing Countries, 85(4), 2019.

[6] Boerman, S. C.; Kruikemeier, S. (2016). Consumer responses to promoted tweets sent by brands and political parties. Computers in Human Behavior, 65, pp. 285–294, 2016.

[7] Chen, Y.; Fay, S.; & Wang, Q. (2011). The role of marketing in social media: How online consumer reviews evolve. Journal of interactive marketing, 25(2), pp. 85-94, 2011.

[8] Cheung, M. F. Y.; To, W. M. (2016). Service co-creation in social media: An extension of the theory of planned behavior. Computers in Human Behavior, 65, pp. 260–266, 2016.

[9] De Vries, L.; Gensler, S.; Leeflang, ES.H. (2012). Popularity of brand posts on brand fan pages: an investigation of the effects of social media marketing. Journal of Interactive Marketing, 26(2), pp. 83-91, 2012.

[10] Digital 2022 global overview report, https://datareportal.com/reports/digital-2022-global-overview-report, downloaded: [July, 12th 2023]

[11] Dwivedi, Y. K.; Ismagilova, E.; Hughes, D. L.; Carlson, J.; Filieri, R.; Jacobson, J.; Wang, Y. (2021). Setting the future of digital and social media marketing research: Perspectives and research propositions. International Journal of Information Management, 59, 102168, 2021.

[12] Flynn, L. R.; Goldsmith, R. E.; Pollitte, W. (2016). Materialism, status consumption, and market involved consumers. Psychology & Marketing, 33(9), pp. 761-776, 2016.

[13] Kaplan, A. M.; Haenlein, M. (2010). Users of the world, unite! The challenges and opportunities of Social Media. Business horizons, 53(1), pp. 59-68, 2010.

[14] Khajeheian, D.; Kolli, S. (2020). Digital games get viral on social media: A social network analysis of Pokémon Go on Twitter. International Journal of Web Based Communities, 16(3), pp. 262–278, 2020.

[15] Khan, M. L. (2017). Social media engagement: What motivates user participation and consumption on YouTube? Computers in Human Behavior, 66, pp. 236–247, 2017.

[16] Kian, T. P.; Boon, G. H.; Fong, S. W. L.: Ai, Y. J. (2017). Factors that influence the consumer purchase intention in social media websites. Int. J Sup. Chain. Mgt, 6(4), pp. 208-214, 2017.

[17] Kim, E.E.K.; Mattila, A.S.; Baloglu, S. (2011). Effects of gender and expertise on consumers' motivation to read online hotel reviews'. Cornell Hospitality Quarterly, 52 (4), pp. 399–406,2011.

[18] Kircaburun, K.; Alhabash, S.; Tosuntaş, Ş. B.; Griffiths, M. D. (2020). Uses and gratifications of problematic social media use among university students: A simultaneous examination of the Big Five of personality traits, social media platforms, and social media use motives. International Journal of Mental Health and Addiction, 18, pp. 525-547, 2020.

[19] Lin, X.; Wang, X. (2020). Examining gender differences in people's information-sharing decisions on social networking sites. International Journal of Information Management, 50, pp. 45-56, 2020.
[20] Lu, H. P.; Hsiao, K. L. (2010). The influence of extro/introversion on the intention to pay for social networking sites. Information & Management, 47(3), pp. 150-157, 2010.
[21] Mangold, W. G.; Faulds, D. J. (2009). Social media: The new hybrid element of the promotion mix. Business horizons, 52(4), pp. 357-365, 2009.
[22] McAndrew, F. T.; Jeong, H. S. (2012). Who does what on Facebook? Age, sex, and relationship status as predictors of Facebook use. Computers in human behavior, 28(6), pp. 2359-2365, 2012.
[23] Mekawie, N.; Hany, A. (2019). Understanding the factors driving consumers' purchase intention of over the counter medications using social media advertising In Egypt: (A facebook advertising application for cold and flu products). Procedia Computer Science, 164, pp. 698–705,2019.
[24] Moghadamzadeh, A.; Ebrahimi, P.; Radfard, S.; Salamzadeh, A.; Khajeheian, D. (2020). Investigating the role of customer co-creation behavior on. Social Media Platforms in Rendering Innovative Services. Sustainability, 12(17), 6926, 2020.
[25] Muhammad, S. S.; Dey, B. L.; Alwi, S. F. S.; Kamal, M. M.; Asaad, Y. (2022). Consumers' willingness to share digital footprints on social media: the role of affective trust. Information Technology & People, pp.1-36, 2022.
[26] Muhammad, S. S.; Dey, B. L.; Weerakkody, V. (2017). Analysis of factors that influence customers' willingness to leave big data digital footprints on social media: A systematic review of literature. Information Systems Frontiers, pp. 1-18, 2017.
[27] Narangajavana, Y.; Fiol, L. J. C.; Tena, M. Á. M.; Artola, R. M. R.; García, J. S. (2017). The influence of social media in creating expectations. An empirical study for a tourist destination. Annals of tourism research, 65, pp. 60-70, 2017.
[28] Park, J.; Hyun, H.; Thavisay, T. (2021). A study of antecedents and outcomes of social media WOM towards luxury brand purchase intention. Journal of Retailing and Consumer Services, 58, 102272, 2021.
[29] Raacke, J.; Bonds-Raacke, J. (2008). MySpace and Facebook: Applying the uses and gratifications theory to exploring friend-networking sites. Cyberpsychology & behavior, 11(2), pp. 169-174.
[30] Rosenblatt MBA, M., Ramirez, C., & Ouloupis, S. (2016). The Changing Face of Entrepreneurship. Northeast Business and Economics Association (NBEA) 2016
[31] Sharma, S.; Rehman, A. (2012). Assessing the impact of web 2.0 on consumer purchase decisions: Indian perspective. International Journals of Marketing and Technology, 2(7), pp. 125-138, 2012.
[32] Sheldon, P.; Bryant, K. (2016). Instagram: motives for its use and relationship to narcissism and contextual age. Computers in Human Behavior, 58, pp. 89–97, 2016.
[33] Sohaib, M.; Hui, P.; Akram, U. (2018). Impact of eWOM and risk-taking in gender on purchase intentions: evidence from Chinese social media. International Journal of Information Systems and Change Management, 10(2), pp. 101-122, 2018.
[34] Song, B. L.; Liew, C. Y.; Sia, J. Y.; Gopal, K. (2021). Electronic word-of-mouth in travel social networking sites and young consumers' purchase intentions: an extended information adoption model. Young Consumers, 22(4), pp. 521-538, 2021.
[35] Suderman, J. (2016). Generation Alpha: marketing or science. Acta Educationis Generalis, 7 (1), pp. 107–115, 2016.
[36] Trawnih, A.; Yaseen, H.; Al-Adwan, A. S.; Alsoud, A. R.; Abdel Jaber, O. (2021). Factors influencing social media adoption among smes during COVID-19 crisis. Journal of Management Information and Decision Sciences, 24(6), pp. 1–18, 2021.

[37] Turban E; King D; Lang J. (2009). Introduction to electronic commerce. Pearson Education, Inc.: Upper Saddle River, NJ; 2009.
[38] Vanani, I. R.; Majidian, S. (2019). Literature review on big data analytics methods.Social media and machine learning, Published: October 24th, 2019.
[39] Venkatesh, V.; Thong, J. Y. L.; Xu, X. (2012). Consumer Acceptance and Use of Information Technology: Extending the Unified Theory of Acceptance and Use of Technology. MIS Quarterly, 36(1), pp. 157–178, 2012.
[40] Wall Emerson, R. (2023). Mann-Whitney U test and t-test. Journal of Visual Impairment & Blindness, 117(1), pp. 99–100, 2023.
[41] Wang, Y.; Herrando, C. (2019). Does privacy assurance on social commerce sites matter to millennials? International Journal of Information Management, 44, pp. 164–177,2019.
[42] Xu, F.; Pan, Z.; Xia, R. (2020). E-commerce product review sentiment classification based on a naïve Bayes continuous learning framework. Information Processing & Management, 57(5), 102221, 2020.
[43] Yusuf, A. S.; Che Hussin, A. R.; Busalim, A. H. (2018). Influence of e-WOM engagement on consumer purchase intention in social commerce. Journal of Services Marketing, 32(4), pp. 493–504, 2018.
[44] Zhang, Y.; Dang, Y.; Chen, H. (2013). Research note: Examining gender emotional differences in Web forum communication. Decision Support Systems, 55(3), pp. 851-860, 2013.
[45] Zhou, L.; Wang, T. (2014). Social media: A new vehicle for city marketing in China. Cities, 37, pp. 27–32, 2014.

Original scientific paper / Izvorni znanstveni rad

UTJECAJ OGLAŠAVANJA I KORISNIČKI GENERIRANOG SADRŽAJA NA DOŽIVLJAJ O PROIZVODU

DARIJA IVANKOVIĆ
Veleučilište „Lavoslav Ružička“ u Vukovaru
Županijska 50, 32000 Vukovar, Hrvatska
darija.ivankovic@vevu.hr

JELENA STJEPANOVIĆ
Doktorska škola Sveučilišta J. J. Strossmayera
Trg Svetog Trojstva 3, 31000 Osijek, Hrvatska
jstjepanovic.ds@unios.hr

SAŽETAK

U današnje vrijeme digitalizacije i digitalne tehnologije kada su potrošači okrenuti online komunikaciji i društvenim mrežama, skloniji su pisanju ili čitanju korisnički generiranog sadržaja koji se može referirati kroz ocjene ili recenzije proizvoda/usluga od strane korisnika. Korisnički generiran sadržaj (UGC) smanjuje troškove promocije i oglašavanja u marketingu jer proizvod/usluga dolazi do izražaja i dovodi do rasta potražnje. U radu se prikazuju i analiziraju načini korisnički generiranog sadržaja - od recenzije, uporabe hashtag znaka, video sadržaja, gamifikacije pa sve do sezonski korisničkog generiranog sadržaja. Na ovaj se način humanizira marketing što je od izuzetne važnosti budući da se stvara moćna višekanalna marketinška strategija. Cilj rada je utvrditi utjecaj korisnički generiranog sadržaja na doživljaj o proizvodu/usluzi te povjerenju potrošača u isti. Istraživanje je provedeno putem Google obrasca tijekom mjeseca lipnja i srpnja 2023. godine. Rezultati istraživanja sugeriraju doživljaje (stajališta) potrošača na proizvode/usluge s obzirom na korisničke recenzije, preporuke, hashtag znak, video sadržaj te učešće korisnika u gamifikaciji.

KLJUČNE RIJEČI: marketing, digitalna komunikacija, oglašavanje, korisnički generiran sadržaj, doživljaj potrošača

IMPACT OF ADVERTISING AND USER-GENERATED CONTENT ON THE PRODUCT EXPERIENCE

ABSTRACT

In today's era of digitization and digital technology, when consumers are focused on online communication and social networks, they are more inclined to write or read user-generated content that can be referenced through ratings or reviews of products/services by users. As the product/service is exposed, user-generated content (UGC) reduces marketing promotion and advertising costs, which leads to a growth in demand. The paper presents and evaluates the

methods of user-generated content, including reviews, hashtags, video content, gamification, and seasonal user-generated content. In this way, marketing is humanized, which is extremely important since it creates a powerful multi-channel marketing strategy. The purpose of the research is to assess the impact of user-generated content on the product/service experience and the consumer's trust in it. The research was conducted through a Google form during the months of June and July 2023. The research findings indicate that consumers' opinions about products/services are influenced by user reviews, recommendations, hashtags, video content, and user participation in gamification.

KEYWORDS: marketing, digital communication, advertising, user-generated content, consumer experience

1. UVOD

Korisnički generiran sadržaj pomaže da kvalitetni proizvodi koji su plasirani na tržište dobiju poseban oblik značenja u potrošačkoj svijesti. To znači da korisnici nakon što konzumiraju proizvod imaju mogućnost recenziranja proizvoda s jedne strane, dok s druge strane tvrtke dobiju besplatno oglašavanje od strane korisnika. Psihološki promatrano, ljudi su skloniji kupnji proizvoda koje im je netko preporučio i koje je već netko isprobao. Nakon što je sam proizvod dobio pozitivne recenzije, osobe koje su zadužene za proizvodnju, prodaju, distribuciju i promociju moraju održati svoju kvalitetu ili je pak postaviti na razinu više [Živković, 2020].

Korisnički generiran sadržaj (UGC) je izvorni sadržaj povezan s proizvodom ili uslugom koji su izradili pojedinci (korisnici), a ne sam brend. Naab i Sehl (2017) korisnički generiran sadržaj definiraju vodeći se sljedećim kriterijima: UGC karakterizira stupanj osobnog doprinosa, UGC mora biti objavljen, sadržaj je stvoren izvan područja profesije odnosno profesionalne rutine. Također, dolazi u raznim oblicima, uključujući ažuriranja društvenih medija, recenzije, postove na blogovima, hashtag, video sadržaj i slično. Kupci ga mogu dijeliti putem videozapisa, foruma s pitanjima i odgovorima ili fotografija koje prikazuju njihove kupnje. Budući da je vođen iskustvom korisnika, UGC je u poslovnoj praksi prepoznat kao najpouzdaniji, najvjerodostojniji i autentični oblik sadržaja u usporedbi s marketinškim sadržajem koji promiču robne marke.

Cilj istraživanja je utvrditi utjecaj korisnički generiranog sadržaja (recenzije, uporabe hashtag znaka, video sadržaja, gamifikacije) na doživljaj o proizvodu/usluzi te povjerenju potrošača u isti.

2. OGLAŠAVANJE I KORISNIČKI GENERIRAN SADRŽAJ

Navike korisnika društvenih mreža se vrlo brzo mijenjaju, a ponajviše ovise o novim trendovima tehničkih postavki i korporacijama [Jakopović, Mikelić Preradović, 2016]. Cokarić i suradnici (2019) ukazuju kako se korisnici sve više uključuju u društvene mreže i interaktivne stranice s ciljem dijeljenja i kreiranja sadržaja u svrhu recenziranja, što recipročno utječe na važnost korisnički generiranog sadržaja u stvaranju doživljaja o proizvodu/usluzi. Ovaj rast sadržaja koji generiraju korisnici, također je utjecao na tradicionalno ponašanje pri kupnji. Kupci su prihvatili nove komunikacijske kanale kao što su mikroblogovi i društvene mreže koji im omogućuju ne samo da razgovaraju s prijateljima i poznanicima o svom iskustvu kupnje,

već i da traže mišljenja potpunih stranaca kao dio procesa donošenja odluka. Otkrivanje što kupci misle o određenim proizvodima ili robnim markama kao i otkrivanje kupovnih navika i preferencija, tradicionalno je bio skup i dugotrajan proces koji je uključivao korištenje metoda kao što su fokusne grupe i ankete. Međutim, novi scenarij zahtijeva duboku procjenu trenutnih tehnika istraživanja tržišta kako bi se bolje protumačio ovaj brzo rastući trend [Vasquez i sur., 2014]. Iako postoje brojni načini kako se korisnički generirani sadržaj koristi, za potrebe rada se izdvaja glavnih pet načina koji uključuju: recenzije, hashtag, video sadržaj, gamifikaciju i sezonsko korisnički generiran sadržaj.

Chacon (2019) navodi kako 70% potrošača pregledava proizvode prije kupnje, tako da recenzije dokazuju koliko uistinu vrijedi proizvod/usluga. Dakle, recenzije potencijalnim kupcima pružaju pouzdanost i provjerljivost proizvoda/usluge od strane potrošača. Ocjene i recenzije mogu uvelike pomoći u povećanju prodaje, posebice putem web shopa te da se izgradi pouzdanost i poboljša stopa konverzije. Prema anketi TurnTo Networks (2017) „Glas potrošača: korisnički generiran sadržaj i korisničko iskustvo“ , 88% potrošača u SAD-u vjeruje preporuci proizvoda koja dolazi izravno od prijatelja, što ih čini najpouzdanijim izvorom za odluke o kupnji. Ista studija pokazuje da 90% potrošača u SAD-u također ocjenjuje online preporuke drugih korisnika kao vrlo utjecajne na njihove odluke o kupnji. Sadržaj koji generiraju korisnici daje im sigurnost u njihovoj odluci da nešto kupe, a većina smatra UGC daleko zanimljivijim od sadržaja koji je stvorio sam brend. U Republici Hrvatskoj postoje tek skromna istraživanja korisnički generiranog sadržaja i doživljaja o kupnji. Pavić (2020) u svom istraživanju apostrofira kako 96,27% ispitanika čita recenzije prije odabira hotela te zaključuje kako recenzije imaju veću ulogu od video sadržaja koje utječu na konačan izbor hotela i kupovinu usluge. Slični rezultati pronalaze se u radu autora Cokarić, Lončarić i Perišić (2019) koji dokazuju kako recenzije objavljenje na web stranici ili društvenim mrežama pomažu potencijalnim gostima stvoriti određena očekivanja o restoranu te im pomažu pri odabiru restorana. S druge strane, Roje (2022) istražuje ulogu UGC-a pri odabiru kupnje pametnog telefona te dokazuje kako potrošači čitaju recenzije prije kupovine proizvoda koje im pomažu pri odabiru/kupovine pametnog telefona (na odluku o kupnji utječu pozitivne recenzije, dok negativne u manjoj mjeri utječu na ispitanike). Nadalje, dokazuje kako ispitanici više vjeruju korisnički generiranom sadržaju nego promotivnom materijalu. Da potrošači više vjeruju korisnički generiranom sadržaju nego promotivnom materijalu, potvrđuju i Kwiatek i suradnici (2021) koji zaključuju kako potrošači stvaraju negativnu sliku o proizvodu/usluzi ukoliko naiđu na negativan korisnički generiran sadržaj, a što se kasnije reflektira na buduće kupovine. Ožić Paić (2018) ukazuje kako djelomično postoji razlika u korisničkim osvrtima obzirom na vrstu proizvoda/usluge te korisnički osvrti s uključenim pozitivnim i negativnim komentarima rezultiraju značajno većim percipiranim povjerenjem od osvrta s isključivo pozitivnim ili negativnim komentarima.

U poboljšanju stope konverzije se također izdvaja i uporaba hashtag znaka. Bebegal-Mirabent i Cabellero (2023) navode kako tvrtke danas koriste sve veću količinu resursa za stvaranje sadržaja društvenih medija kako bi izazvale utjecaj i angažirale kupce. Način na koji brendovi komuniciraju s potencijalnim kupcima od iznimne je važnosti jer stvara njihov internetski identitet i prisutnost, a to je u konačnici povezano s lojalnošću kupaca i u vezi s tim veliki značaj ima hashtag znak koji pruža viralnost proizvodu/usluzi. Magdić (2019), s druge strane, ističe da kako bi se poboljšao ugled poduzeća, povećala prepoznatljivost i popularnost njezine marke, usluge ili proizvoda putem društvenih medija, poduzeća se sve češće okreću marketinškim strategijama koje uključuju praćenje hashtagova i iskorištavanje aktualnih događaja. Također, napominje da je ključno za povećanje broja pratitelja profila korištenje hashtagova koji potiču svijest o proizvodu ili usluzi putem uključivanja korisnika i potencijalnih kupaca.

Stipetić i suradnici (2021) naglašavaju kako većina potrošača prvo istražuje YouTube prije nego što donese odluku o kupnji proizvoda ili usluge. Ovime se ukazuje na značaj video sadržaja kao ključnog alata za komunikaciju s potrošačima, jer je njegova popularnost izuzetno visoka, bilo da se koristi u svrhu obrazovanja ili zabave. Evidentno je dakle kako TikTok, kao jedna od najpoznatijih i najkorištenijih društvenih mreža, funkcionira temeljem video sadržaja među kojima se mogu pronaći mnogobrojni recenzirajući materijali gdje se iznose mišljenja ili iskustva s proizvodima ili uslugama. Budući da društveni mediji uključuju korisnike koji preuzimaju aktivnu ulogu i stvaraju sadržaj, mogu biti utjecajniji od tradicionalnog marketinga [Kanchan i Gaidhane, 2023]. Nadalje, Pratiwi, Myanya i Rahyadi [2022] navode da korisnici komunikacijom na TikToku, pomoću video sadržaja, nude vrijedne uvide za istraživače, praktičare i kreatore politika u području društvenih medija i komunikacijskih studija.

Istraživanje utjecaja gamifikacije na promociju destinacije sugerira kako gamifikacija obogaćuje promociju i stvara bolju prepoznatljivost [Jakus, 2019]. Nadalje, gamifikacija kao jedan od oblika korisnički generiranog sadržaja predstavlja učenje ili u ovom slučaju stvaranje lojalnosti i pozitivne slike o tvrtkama kroz igru. Najčešće se gamifikacija očituje kroz nagradne igre, brojne popuste i pogodnosti u smislu skupljanja bodova, igranja igrica na aplikacijama ili skupljanja znački i titula na grupama ili forumima. Općenito, današnja konkurencija može se jačati prihvaćanjem ideje holističkog pristupa marketingu i brendiranju, te aktivnim uključivanjem korisnika ne samo u marketinške poruke, već i u proces kreiranja inovativnih proizvoda koji udovoljavaju njihovim sve sofisticiranijim zahtjevima [Hordov i sur, 2019]. Također, autori ističu da je gamifikacija značajna i inovativna strategija komunikacije koja stvara pozitivno korisničko iskustvo i potiče emocije, što ima ključnu ulogu u području marketinga.

Konačno, sezonski korisnički generiran sadržaj je od velike važnosti u specifičnim razdobljima godine poput ljeta – ljetovanja, zime – zimovanja ili svjetskog dana vode, sreće i slično kada se objedinjuju svi načini komunikacije s potencijalnim potrošačima kako bi se postigao reach ili povećala stopa konverzije. Tada su ljudi usmjereni na navedeni period i lako je doprijeti do potrošača korištenjem digitalnih trendova jer su potencijalni kupci prisutni zbog važnosti sezone. Na taj način brend potiče svoje obožavatelje na stvaranje angažmana i povećanja svijesti o proizvodu/usluzi, a Albuquerque i sur. (2012) ističu kako sezonsko korisnički generiran sadržaj ima veću ulogu u percepciji potrošača od cijene proizvoda/usluge. Prikaz 1. ilustrira prednosti i nedostatke korisnički generiranog sadržaja.

Prikaz 1. Prednosti i nedostaci korisnički generiranog sadržaja

Izvor: autori prema Kunsman, 2023. i Wiele, 2023.

3. METODOLOGIJA RADA

Istraživanje uz provedeno putem anketnog upitnika. Anketni upitnik strukturiran je u dva dijela. Prvi dio upitnika je obuhvaćao 20 tvrdnji strukturiranog tipa uz primjenu Likertove ljestvice od 5 stupnjeva (1 – u potpunosti se ne slažem, 2 – ne slažem se, 3 – niti se slažem, niti se ne slažem, 4 – slažem se i 5 – u potpunosti se slažem). Ovaj set pitanja oslanja se na prethodna istraživanja (Tomašek, 2019, Cokarić i sur,. 2019) te istražuje stavove ispitanika o utjecaju korisnički generiranog sadržaja na doživljaj o proizvodu/usluzi (recenzije, hashtag, video sadržaj i gamifikacija). Drugim dijelom upitnika prikupljeni su podaci o socio-demografskim obilježjima ispitanika: spol, dob, stupanj obrazovanja, županija te mjesečni prihod. Istraživanje je provedeno putem Google obrasca u razdoblju od 01. lipnja do 20. srpnja 2023. godine. U istraživanju je sudjelovalo 107 ispitanika (N=107). Podaci su uneseni i obrađeni u statističkom programskom paketu SPSS. Obrada podataka provedena je deskriptivnom statistikom i korelacijskom analizom.

U radu su postavljenje sljedeće hipoteze:
H1: Recenzije imaju pozitivan utjecaj na potrošače prilikom kupovine proizvoda/usluge.
H2: Video sadržaj, gamifikacija i hashtag imaju pozitivan utjecaj na potrošače prilikom kupovine proizvoda/usluge.
H3: Postoji povezanost između utjecaja recenzije i video sadržaja na potrošačev izbor proizvoda/usluge.

4. REZULTATI I RASPRAVA

U istraživanju je sudjelovalo 107 (N=107) ispitanika od kojih je 64,5% ženskog, a 35,5% muškog spola. Većina ispitanika živi na području Osječko-baranjske županije 51,4%, 34,6% na području Vukovarsko-srijemske županije, dok manji broj ispitanika obuhvaćenih istraživanjem živi u drugim županijama Hrvatske (14%). Prosječna dob ispitanika iznosi 37 godina. Najveći dio ispitanika, njih 37,4%, završilo je srednju školu, 73,8% ispitanika je zaposleno te su im prosječna primanja u rangu od 1.001 – 2.000 eura. U Tablici 1. prikazana su socio-demografska obilježja ispitanika.

Tablica 1. Socio-demografska obilježja ispitanika

Varijable		N	%
Spol	Muško	38	35,5
	Žensko	69	64,5
Dob	16 – 20	15	14
	21 – 30	25	23,5
	31 – 40	30	28
	41 – 50	30	28
	50 + godina	7	6,5
Stupanj obrazovanja	Osnovna škola	10	9,3
	Srednja škola	40	37,4
	Preddiplomski studij	18	16,8
	Diplomski studij	29	27,2
	Specijalistički ili doktorski studij	10	9,3
Mjesečni prihodi kućanstva	Do 500 eura	1	0,9
	501 – 1.000 eura	15	14

	1.001 – 2.000 eura	37	34,6
	2.001 – 2.500 eura	21	19,6
	2.501 – 3.000 eura	11	10,3
	Više od 3.000 eura	13	12,1
	Ne želim se izjasniti	9	8,4

Izvor: autori

Nadalje, većina ispitanika njih 62,6% provodi dnevno u prosjeku dva sata na društvenim mrežama. Ispitanici najčešće društvene mreže koriste koje s ciljem informiranja i kupovine proizvoda/usluga (47%) zabave (45%), zbog posla (4,5%), a kao ostale razloge navode kontakt (komunikacija) s prijateljima te dosada (Prikaz 2.).

Prikaz 2. Razlozi korištenja društvenih mreža

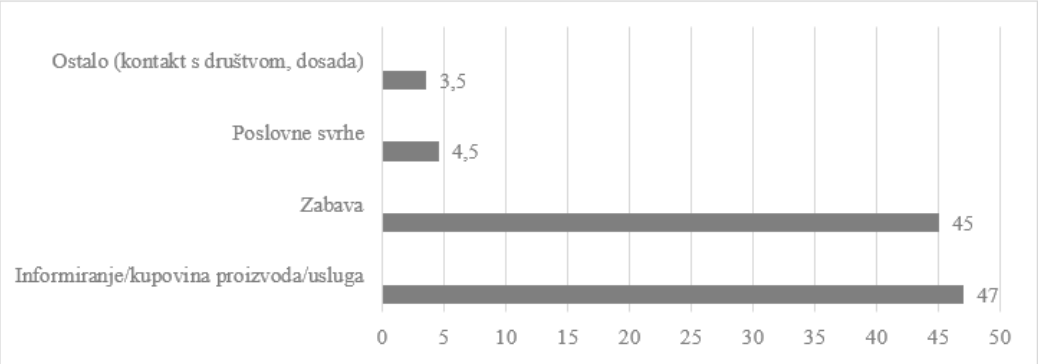

Izvor: autori

Prva hipoteza se odnosila na utjecaj recenzija na potrošačev izbor. U Tablici 2. prikazani su rezultati istraživanja.

Tablica 2. Utjecaj recenzija na doživljaj o proizvodu/usluzi

TVRDNJA	N	AS	Me	Mo	SD
Prije kupnje proizvoda/usluge čitam recenzije.	107	3,94	4,00	5	0,979
Kada se dvoumim oko izbora proizvoda/usluge čitam recenzije.	107	4,34	5,00	5	0,800
Prije nego što isprobam novi proizvod/uslugu čitam recenzije.	107	4,01	4,00	5	0,986
Ukoliko pročitam/pogledam negativnu recenziju neću kupiti proizvod/uslugu.	107	3,51	3,00	3	1,152
Ukoliko pročitam/pogledam pozitivnu recenziju kupit ću proizvod/uslugu.	107	3,57	3,00	3	0,972
Kada pogledam video ili pročitam članak o prednostima nekog proizvoda/usluge dobijem želju da ga/je probam.	107	3,60	4,00	4	1,089
Recenzije se u pravilu pokažu opravdanima (točnim).	107	3,50	4,00	4	0,782
Svoja mišljenja o proizvodu/usluzi dijelim s drugima.	107	3,56	4,00	4	1,134
Svoja iskustva (recenzije) dijelim na društvenim mrežama.	107	1,74	1,00	1	1,085
Prije bih ostavila/o pozitivne nego negativne recenzije.	107	3,01	3,00	3	1,263
Objavljujem recenzije na službenoj stranici proizvoda/usluge.	107	1,88	1,00	1	1,257
Nakon objave influencera o određenom proizvodu/usluzi, poželim koristiti isti/istu.	107	2,29	2,00	1	1,205

Izvor: autori

Prva hipoteza odnosila se na ispitivanje stajališta o utjecaju recenzija na kupnju proizvoda/usluge (Tablica 2.). Rezultati pokazuju kako ispitanici čitaju recenzije prije kupnje proizvoda/usluge (AS=3,94, SD=0,979), čitaju recenzije ukoliko se dvoume oko izbora proizvoda/usluge (AS=4,34, SD=0,800) te su im recenzije važne prije kupovine novog proizvoda (AS=4,01, SD=0,986).

Ispitanici su izrazili i svoja stajališta kupovine proizvoda ili usluge koji imaju negativnu recenziju. Naime, negativna recenzija utječe na njihovu odluku da proizvod uglavnom neće kupiti (AS=3,5, SD=1,152). Ista stajališta pokazuju i za kupovinu proizvoda ili usluge koji imaju pozitivnu recenziju (AS=3,57, SD=0,972). Dakle, ukoliko je proizvod pozitivno ocijenjen, isti će uglavnom i kupiti. S druge strane, rezultati istraživanja pokazuju da im je motivirajući čimbenik za kupovinu video sadržaj ili članak u kojima se prikazuju odnosno navode prednosti proizvoda/usluge (AS=3,6, SD=1,089).

Rezultati istraživanja također pokazuju kako se recenzije u pravilu pokazuju opravdanima (AS=3,5, SD=0,782). Ispitanici dijele svoja mišljenja s drugima (prijatelji, poznanici, rodbina, AS=3,56, SD=1,134), ali ne ostavljaju recenzije na društvenim mrežama (AS=1,74, SD=1,085). Ukoliko se odluče ostaviti recenziju, češće ostavljaju pozitivnu nego negativnu recenziju (AS=3,01, SD=1,263). Zanimljiv je rezultat koji se odnosi na influencere. Naime, ispitanici ne vjeruju influencerima i nakon njihovih objava ne požele kupiti proizvod ili uslugu (AS=2,29, SD=1,205).

Druga hipoteza se odnosila na utjecaj hashtaga, video sadržaja i gamifikacije na potrošačev izbor. U Tablici 3. prikazani su rezultati istraživanja.

Tablica 3. Utjecaj hashtaga, video sadržaja i gamifikacije na doživljaj o proizvodu

Tvrdnja	N	AS	Me	Mo	SD
Često koristim hashtag u objavama.	107	1,82	1,00	1	1,204
Kupit ću proizvod/uslugu jer ima puno korisnika koji stavljaju hashtag tog proizvoda/usluge.	107	1,55	1,00	1	0,860
Hashtag me potiče na kupnju.	107	1,53	1,00	1	0,914
Prije kupnje proizvoda/usluge gledam video sadržaj.	107	3,34	3,00	3	1,173
Kupit ću proizvod zahvaljujući video sadržaju.	107	3,12	3,00	3	1,179
Kada mi na društvenim mrežama iskoči video sadržaj o nekom proizvodu/usluzi dobijem želju da ga/je kupim.	107	2,88	3,00	3	1,315
Sudjelujem u nagradnim igrama na društvenim mrežama.	107	2,09	1,00	1	1,321
Prije ću koristiti usluge/proizvode gdje mogu skupljati bodove ili ostvarivati popuste nego one gdje nemam tu opciju (npr. Lukoil, DM.)	107	3,12	3,00	4	1,465

Izvor: autori

Druga hipoteza se odnosila na ispitivanje stajališta o utjecaju hashtaga, video sadržaja i gamifikacije na doživljaj o proizvodu (Tablica 2.). Rezultati pokazuju kako ispitanici ne koriste hashtag u svojim objavama (AS=1,21, SD=1,204). Nadalje, ispitanici neće kupiti proizvod ili

uslugu jer puno korisnika koristi hashtag određenog proizvoda (AS=1,55, SD=0,860) te su jasnog stava kako ih hashtag ne potiče na kupovinu (AS=1,53, SD=0,914).

Većina ispitanika uglavnom gleda video sadržaj prije kupovine proizvoda ili usluge (AS=3,5, SD=1,152), ali su neutralnog stava što se tiče kupovine proizvoda ili usluge nakon pogledanog video sadržaja (AS=3,12 SD=1,179).

Rezultati također pokazuju kako ispitanici u pravilu ne sudjeluju u gamifikaciji (nagradnim igrama) na društvenim mrežama (AS=2,09, SD=1,321), niti su motivirani kupnjom proizvoda u trgovinama u kojima mogu sakupljati bodove i/ili ostvarivati popuste (AS=3,12, SD=1,465).

Treća hipoteza se odnosila na utjecaj recenzije i video sadržaja na potrošačev izbor. U Tablici 4. prikazani su rezultati korelacijske analize.

Tablica 4. Utjecaj recenzije i video sadržaja na potrošačev izbor

		Prije nego što isprobam novi proizvod/uslugu čitam recenzije.	Prije kupnje proizvoda/usluge gledam video sadržaj.
Prije nego što isprobam novi proizvod/uslugu čitam recenzije.	Pearsonov koeficijent korelacije (r)	1	,275**
	Sig. (jednosmjerno testiranje)		,000
	N	107	107
Prije kupnje proizvoda/usluge gledam video sadržaj.	Pearsonov koeficijent korelacije (r)	,275**	1
	Sig. (jednosmjerno testiranje)	,000	
	N	107	107

Izvor: autori

Primjenom Pearsonovog koeficijenta korelacije utvrđena je slaba pozitivna povezanost između utjecaja recenzije i utjecaja video sadržaja na potrošačev izbor proizvoda/usluge ($r = 0,275$, $p < 0,001$). Ovaj rezultat upućuje na zaključak kako potrošači koji čitaju recenzije gledaju i video sadržaj prije kupovine.

Rezultati provedenog empirijskog istraživanja pokazuju kako ispitanici imaju pozitivne stavove o korisnički generiranom sadržaju u smislu recenzija i video sadržaja te će kupiti proizvod ili uslugu nakon čitanja recenzije odnosno gledanja video sadržaja (potvrđuju se hipoteze H1 i H3). Ovi nalazi potvrđuju rezultate prethodnih istraživanja u kojima se naglašava važnost recenzija u različitim sektorima poslovanja. Pavić dokazuje da potrošači često provjeravaju recenzije prije nego što odluče rezervirati hotel, dok Roje potvrđuje da se recenzije često koriste pri odabiru/kupovini pametnog telefona. Autorice Cokarić, Lončarić i Perišić zaključuju kako u velikoj mjeri gosti koriste korisnički generirani sadržaj na društvenim mrežama kako bi stvorili predodžbu o usluzi koju mogu očekivati prije konzumacije u restoranu. Utjecaj video sadržaja na odluku o kupnji također se može smatrati dopunom prethodnim istraživanjima. Stipetić i suradnici naglašavaju važnost video sadržaja kao sredstva komunikacije te ističu da većina potrošača koristi video sadržaj kako bi se informirala o proizvodima i uslugama što podržava tvrdnju da video sadržaj ima utjecaj na donošenje odluke o kupnji.

No s druge strane, ispitanicima hashtag i gamifikacija ne utječu na doživljaj o proizvodu/usluzi te se hipoteza H2 odbacuje. Budući da se u radu ispitivao generalni utjecaj gamigikacije na

kupovinu proizvoda/usluga, dobiveni rezultati ne mogu se povezati s prethodnim istraživanima. Rezultati istraživanja ukazuju kako ispitanici nisu skloni sudjelovati u gamifikaciji, niti ih gamifikacija potiče na kupnju. S druge strane, autori Jakus i Kordov i suradnici ističu važnost gamifikacije, posebno u kontekstu doživljaja turističkih proizvoda. Smatraju je ključnim alatom i inovativnim načinom komunikacije koji stvara pozitivno korisničko iskustvo i potiče emocionalnu reakciju. Može se zaključiti kako se gamifikacija ne može općenito primijeniti jer ispitanici nisu podložni istim utjecajima u svim sferama kupnje. Stoga je prijedlog za buduća istraživanja identificirati područje u kojem gamifikacija igra značajnu ulogu u odabiru proizvoda ili usluge. Nadalje, iako se u poslovnoj praksi naglašava važnost hashtagova posebice za poboljšanje ugleda poduzeća, prepoznatljivost marke te popularnost proizvoda/usluge putem društvenih medija, rezultati istraživanja pokazuju kako ispitanici ne percipiraju hashtagove te oni ne utječu na njihovu odluku o kupnji.

5. ZAKLJUČAK

Danas, korisnici na društvenim mrežama temeljem kupnje, svojih iskustava i mišljenja generiraju sadržaj koji se naziva korisnički generiran sadržaj. S druge strane, u marketinškom smislu, korisnički generiran sadržaj je sadržaj relevantan za brend i prepoznaje se u obliku online recenzija, fotografija proizvoda, povratnih informacija kupaca, video sadržaja i slično. Također, korisnički generiran sadržaj je vođen iskustvom korisnika proizvoda/usluge i kao takav se u poslovnoj praksi prepoznaje kao pouzdan, vjerodostojan i autentičan oblik sadržaja koji evidentno utječe na proces donošenja odluke o kupnji, čime se daje preporuka poduzećima da više potiču korisnički generiran sadržaj kroz svoje marketinške kampanje, posebice recenzije.

Rezultati istraživanja pokazuju kako su ispitanici aktivni na društvenim mrežama i u većoj mjeri konzumiraju korisnički generiran sadržaj. Provedenom statističkom analizom je utvrđeno kako ispitanici čitaju recenzije prije same kupovine proizvoda/usluge, posebice u situacijama kada se dvoume te prilikom kupovine novih proizvoda/usluga, a recenzije smatraju istinitima i opravdanima. Također, ispitanici svoja iskustva tradicionalno dijele s drugima (word of mouth), ali ne i putem društvenih mreža. Nadalje, ispitanici se više ne koriste hashtag-om, niti ga doživljavaju ukoliko ga netko koristi na objavama što jasno pokazuje kako zasigurno neće kupiti proizvod/uslugu temeljem hashtag-a, tako da se postavlja pitanje za buduća istraživanja koliko je hashtag danas viralan i koristan. Što se tiče video sadržaja, ispitanici u velikoj mjeri gledaju video sadržaje kako bi se informirali o proizvodu/usluzi temeljem čega donose odluku o kupnji. Veliku ulogu zasigurno ima TikTok kao jedna od najutjecajnijih društvenih mreža, posebice za mlađu populaciju. Iako ispitanici najvećim dijelom ne sudjeluju u nagradnim igrama na društvenim mrežama, skupljaju bodove kako bi ostvarili popuste te su spremni instalirati aplikaciju u tu svrhu jer se lakše odlučuju na kupovinu ukoliko imaju kod ili bodove za popust.

Kada se analiziraju rezultati provedenog istraživanja, može se identificirati nekoliko ograničenja. Glavno ograničenje ovog istraživanja odnosi se na činjenicu da je usredotočeno na opću kupovinu proizvoda i usluga, a nije se posebno fokusiralo na određeni sektor. Pretpostavlja se da ispitanici reagiraju različito kada se radi o turističkim uslugama, konzumaciji u restoranu ili nabavi kućanskih potrepština. Drugo ograničenje odnosi se na prostorni obuhvat, u kojem su najvećim dijelom sudjelovali ispitanici iz Slavonije (OBŽ i VSŽ). Za buduća istraživanja preporučuje se uključivanje ispitanika iz svih županija Hrvatske kako bi se proširila reprezentativnost uzorka. Također, prijedlog za buduća istraživanja je ispitati

čimbenike koji utječu na odabir proizvoda/usluga, kao i mjere poboljšanja gamifikacije. Konačno, bez obzira na ograničenja istraživanja, rezultati sugeriraju da potrošači vjeruju i konzumiraju korisnički generirani sadržaj, posebice recenzije i video sadržaj koji imaju signifikantnu ulogu na odluku o kupnji.

REFERENCE

[1] Albuquerwue, P. i sur. (2012). Evaluating Promotional Activities in an Online Two-Sided Market of User-Generated Content. https://pubsonline.informs.org/doi/10.1287/mksc.1110.0685 [08. rujna 2023]

[2] Bebegal-Mirabent, J., Cabellero, X. (2023). Winning post strategies that generate engagement: A QCA aproach. *Intangible Capital*, Vol. 19, No. 3, str. 415-433, 2023.

[3] Chacon, B. (2019). 5 creative UGC Marketing Campaigns to Inspire Your Business. https://later.com/blog/ugc-marketing-campaigns/ [20. lipnja 2023]

[4] Cokarić, D., Lončarić, D., Perišić Prodan, M. (2019). Uloga društvenih mreža u kreiranju doživljaja gostiju u restoranima. *Zbornik radova Veleučilišta u Šibeniku*, (3-4/2019), str. 7-22., 2019.

[5] Hordov, M., Sikirić, D. i Krajnović, A. (2019). Gamifikacija kao poslovni model u digitalnom marketingu i njegova primjena u turizmu. *CroDim,* Vol. 2, No. 1, str. 17-35.

[6] Jakopović, H., Mikelić Preradović, N. (2016). Identifikacija online imidža organizacija temeljem analize segmenata korisnički generiranog sadržaja na hrvatskim portalima. *Media Research: Croatian journal for journalism and the media,* Vol. 22 No. 2, str. 63-82, 2016.

[7] Jakus, A. (2019). Potencijal primjene gamificirane promocije destinacije. Diplomski rad. Sveučilište u Splitu, Ekonomski fakultet.

[8] Kanchan, S., Gaidhane, A. (2023). Social Media Role and It's Impact on Public Health: A Narrative Review. *A Narrative Review. Cureus*, Vol. 15, No. 1, str. 1-10, 2023.

[9] Kunsman, T. (2023). 36 User-Generated Content Statistics That You Can't Ignore, https://everyonesocial.com/blog/user-generated-content-statistics/ [23. lipnja 2023]

[10] Kwiatek, P., Baltezarević, R., Papakonstantinidis, S. (2020). Utjecaj vjerodostojnosti preporuka influencera na društvrnim mrežama na ponašanje potrošača prema markama. Prethodno priopćenje. Američko sveučilište na Bliskom istoku, Vol. 54, No. 3-4, str, 181-196.

[11] Lončarić, D., Perišić Prodan, M. (2019). Uloga društvenih mreža u kreiranju doživljaja gostiju u restoranima. *Collecred papers od Šibenik College*, Vol. 19 No. 3, str. 7-22, Šibenik, Hrvatska.

[12] Magdić, A. (2021). *Utjecaj online komunikacije na promjene stavova i ponašanje potrošača.* Koprivnica, Sveučilište Sjever.

[13] Myanya, K. S., Rahyadi, I. (2022). Exploring The Power of Social Communication on TikTok Trough a Qualitative Literature Review. *Syntax Literature: Journal Ilmiah Indonesia*, Vol. 7, No. 11, str. 17863-17876, 2022.

[14] Naab, T. K., Sehl, A. (2017). Studies of user-generated content: A systematic review. *Journalism, 18*(10), str. 1256-1273, 2017.

[15] Ožić Paić, S. (2018). *Determinante i utjecaj povjerenja u korisničke osvrte u kontekstu online trgovine*. Diplomski rad, Sveučilište u Splitu, Ekonomski fakultet.

[16] Pavić, A. (2020). *Utjecaj online recenzija na imidž i prodaju hotela*. Diplomski rad, Sveučilište u Splitu, Ekonomski fakultet.

[17] Roje, M. (2022). *Uloga sadržaja kreiranog od strane korisnika na društvenim mrežama pri odabiru pametnog telefona*. Diplomski rad. Sveučilište u Zagrebu, Ekonomski fakultet.
[18] Stipetić, L., Benazić, D., Ružić, E. (2021). Behavior of video-sharing social media users. Prethodno priopćenje *CroDiM*, Vol. 4, No. 1, str. 93-106., 2021.
[19] Tomašek, L. (2019). *Utjecaj društvenih mreža na ponašanje potrošača*, Doctoral dissertation, University of Zagreb. Faculty of Organization and Informatics. Zagreb, Hrvatska.
[20] TurnTo Networks (2017) "Hearing the Voice of the Consumer: UGC and the Commerce Experience." https://www.retailtouchpoints.com/topics/omnichannel-alignment/user-generated-content-influences-90-of-shoppers-purchasing-decisions [23. lipnja 2023]
[21] Vázquez, S. i sur. (2014). A classification of user-generated content into consumer decision journey stages. *Neural Networks, 58,* str. 68-81, 2014.
[22] Wiele, R. (2023). The Power of UGC Marketing: Its Effectiveness, Pros & Cons. https://www.linkedin.com/pulse/power-ugc-marketing-its-effectiveness-pros-cons-ruben-van-de-wiele/ [08. rujna 2023]
[23] Živković, L. (2020). *Oglašavanje kroz korisnički generiran sadržaj*. Završni rad, Osijek, Ekonomski fakultet u Osijeku.

Original scientific paper / Izvorni znanstveni rad

COUNTRY-LEVEL DETERMINANTS OF ATTITUDES TOWARD SCIENCE AND TECHNOLOGY AS PREDICTORS OF THE SOCIAL ROBOTS MARKET

JOSIPA VIŠIĆ
University of Split
Faculty of Economics, Business and Tourism
Cvite Fiskovića 5, 21000 Split, Croatia
josipa.visic@efst.hr

ABSTRACT

The social robots market is a fast-growing niche, and it is important to detect which country-level determinants indicate that adjusting might be needed while developing and selling these products in respective countries. K-means cluster analysis, as a form of unsupervised learning algorithm, was performed on data for 2021 using a sample of 51 countries. Data on attitudes toward science and technology have been collected from the World Values Survey (Wave 7), while the rest of the country-level data have been obtained from the World Development Indicators (World Bank) database. Results indicate that the majority (38) of observed countries belong to cluster 2, characterised by the lowest level of the following variables: GDP per capita, the share of the female labour force, the share of the elderly population and the share of Internet users in the population. However, this cluster tends to be the most benevolent towards science and technology. On the other hand, cluster 1, with the relatively high levels of previously mentioned variables, is expected to be the most sceptical towards social robots. Consequently, dealing with the social robots market in developed countries will require adjusting to their specifics.

KEYWORDS: social robots, market, technology, determinants, country-level

1. INTRODUCTION

Economic aspects of technological progress in the form of robotisation and the development of artificial intelligence (AI) have been a prolific research theme for years. However, along with technological progress, ongoing sociological changes are happening in developed and less developed countries, such as the ageing of society, imbalances in labour markets, migrations, etc. Consequently, the economic importance of social robots as a form of non-industrial robots (for detailed classification of robots, cf. Heerink et al., 2010) has risen over the years. From a microeconomic perspective, social robots can satisfy various individual needs (e.g. comfort, companionship, help with chores, etc.). Therefore, they could be a lucrative product for various producers. At the same time, since social robots can be service robots and companion robots, their increased usage might result in significant macroeconomic repercussions, e.g. if they are extensively used in service industries as substitutes for human labour.

Considering all stated and the estimates that the social robots market size is expected to grow from USD 4.26 billion in 2023 to USD 17.32 billion by 2028 (Mordor Intelligence, 2023), this paper focuses on the social robots market observed on a country level. Namely, the aim is to analyse country-level characteristics that are believed to affect attitudes toward science and technology to estimate which countries are more likely to become a lucrative market for social robots. To the author's best knowledge, similar country-level studies on social robots markets have different focuses (cf. Chapter 2) and are mainly related to the economic aspects of designing these robots and the effects of culture on this process and consumers' attitudes. Hence, the cluster analysis results on 51 countries, depending on five different country-level variables, can benefit researchers in the field since they provide a different perspective on the issue. Further, insight into groups of countries that are more likely to become lucrative markets is beneficial to professionals in the field since here presented results, combined with the growing knowledge of differences in cultures regarding acceptance of social robots, can help optimise product development and sales strategies which indirectly decreases companies' costs. Policymakers can also benefit since there are numerous economic and sociological implications in countries that have become significant in terms of the usage of social robots. E.g. in the health sector, social robots can help address shortages in the labour market (Zrinjka, et al., 2019). Still, at the same time, their increased use in the service industry might result in a decreased demand for human labour, causing multiple negative consequences (Dobrosovestnova, et al., 2022). Hence, here presented results can help increase the knowledge on the theme and serve to study further this issue, whose importance will inevitably rise in future.

The paper is structured in the following order. A brief literature overview is presented in the second section, followed by the segment referring to data description and used methodology. The fourth chapter presents the results and discussion, while the fifth chapter provides concluding remarks.

2. A BRIEF LITERATURE OVERVIEW

As Fracasso et al. (2022) stated, while there is a massive body of research on the design and acceptance of social robots in different fields of application, their market potential has rarely been investigated. Namely, to the author's best knowledge, solely studies of Fracasso et al. (2022) and López-Sánchez et al. (2018) are partially similar to this research regarding their general idea. However, their focus and empirical analysis are different. In that sense, Fracasso et al. (2022) focus on the acceptance and marketability of social robots used in assisted living for older adults. Therefore, their survey analysis includes 197 individuals from Italy and Germany, aged 50 to 85, since they are expected to be future users of socially assistive robots in both the health and the domestic domain. Their results, amongst others, indicate that desired characteristics of social robots and readiness to buy them change depending on who is paying them (e.g. health national service/insurance/individual). On the other hand, López-Sánchez et al. (2018) used a cluster analysis on country-level data for 71 countries, but their work-in-progress paper is focused solely on adopting industrial robots.

Papers analysing social robots primarily focus on perception and attitudes depending on culture. Hence, many papers relate to east-west differences in cultures. E.g. Li et al., (2019) analyse the appropriateness of actions of domestic robots as a set of norms within a particular culture, testing differences between the USA and China. Chen et al. (2019) studied social robots' facial expressions, finding that these expressions are not universally recognised, i.e. there are differences in East Asian cultures compared to Western cultures. Marchesi et al. (2021)

analysed differences in the social inclusion of the robot between East and West-type cultures. However, their empirical analysis included an experiment with the humanoid robot iCub and a survey analysis with participants from the UK and China. Similarly, Gjaci et al. (2022) used a social robot Pepper in an experiment to analyse how Indian and non-Indian users react to the same sets of co-speech gestures. Korn et al. (2021) performed empirical analysis on participants from Germany and three Arab countries, providing insight into intercultural and intracultural differences regarding how should a social robot look and behave. Unlike four previous papers, Lim et al. (2020) used a solely theoretical approach, and their research provides an excellent in-depth analysis of studies on social robots that deal with the role of culture in different aspects of human-robot interaction.

Besides many previously mentioned studies focusing on culture as a determinant of various aspects of social robot-human interaction, some studies focus on other consumers' characteristics. E.g. Forgas-Coll et al. (2022) performed an experiment using the TIAGo robot and the survey analysis on mostly Spanish participants to test how consumers' gender and rational thinking (they tested the difference between heuristic and more rational consumers) affect the acceptance of entertainment social robots. On the other hand, Kertész and Turunen (2019) did a survey analysis on Sony AIBO robot owners, studying how their cultural background, age, gender and length of ownership influence expectations towards social robots, and they provide practical guidelines to improve the design of social robots for long-term human-robot interactions.

There are also studies on social robots that focus on a particular socio-economic problem that could, at least to some extent, be diminished by using social robots. In that sense, Suwa et al. (2020) explore differences in perceptions toward home-care robots in Japan, Ireland and Finland in different stakeholders affected by the ageing process (adults aged 65 or older, family caregivers, home-care/health and social care professionals). Contrary to this rather expected usage of social robots, Lugrin et al. (2018), based on their analysis of acceptance considering gender and non-verbal behaviour of Robopec Reeti robot, emphasise the potential of employing social robots in refugee integration into foreign cultures.

Further, there are also theoretical papers with philosophical approaches to social robots, such as Coeckelbergh (2022), offering different perspectives on the relationship between culture and robots, or Sparrow (2020) that deal with the issue of robots' race and their design in a way that tackles this sensitive issue. However, these types of research are not closely related to this paper's focus and, consequently, are not further analysed.

3. DATA DESCRIPTION AND THE METHOD

Empirical analysis has been performed on 51 counties (the list is available in Table 5). Since the paper is focused on attitudes toward science and technology, this analysis included data for 2021, as these are the newest published data on the issue collected from the World Values Survey (Wave 7), while the rest of the country-level data have been obtained from World Development Indicators (World Bank) database in the same year. Detailed definitions of the five used variables are presented in Table 1.

Table 1. Description of variables

Variable	Definition
Tech	% of the population agreed with the statement: "Science and technology are making our lives healthier, easier, and more comfortable." Likert scale has been used in the question where 10 denoted a complete agreement and 1 a complete disagreement. Answers indicating levels of the agreement marked with 8, 9 and 10 have been included in this analysis.
GDPpc	GDP per capita, PPP (current international $)
LabourF	Female labour force; % of the total labour force
Pop65	Population aged 65 and above; % of the total population
Internet	Individuals using the Internet; % of the total population

Source: Author

Attitudes toward science and technology are believed to predict the size and type of social robots market. In that sense, the aim is to detect which country-level determinants indicate that adjusting might be needed while developing and selling these products in respective countries. In that sense, a country's economic strength and population's wealth are measured by GDP per capita. Since social robots belong to a group of normal goods (Pindyck and Rubinfeld, 2013), a higher GDP per capita is expected to increase the possibility of purchasing social robots, i.e. market size in a country is expected to rise. The share of females in the labour force is selected as one of the reflections of culture and the indicator of the country's level of development. Namely, a higher share of females participating in the labour market is more likely to correlate with the higher demand for social robots since social robots could provide care to family members, usually offered by females outside the labour market (Chen, et al., 2017; Michaud, et al., 2010). At the same time, a higher portion of females indicates a developed labour market with the possibility to delegate many job activities to social robots. Finally, a higher percentage of the population using the Internet is believed to be a good indicator of the increasing demand for social robots.

K-means cluster analysis as a form of an unsupervised learning algorithm has been performed on selected data using IBM Statistics SPSS 23. Since this method groups entities (in this case, counties) in clusters similar according to selected variables, it requires determining the number of clusters prior to the analysis. Consequently, considering the number of countries in the sample and the number of used variables, the analysis is formed with three cluster groups. Descriptive statistics for the used data are presented in Table 2.

Table 2. Descriptive statistics

	N	Minimum	Maximum	Mean	Std. Deviation
Tech	51	32.50	81.10	55.039	11.553
GDPpc	51	2333.97	118887.82	25039.408	21609.459
LabourF	51	13.94	52.65	40.1127	9.688
Pop65	51	2.84	29.79	10.974	6.427
Internet	51	16.70	96.75	74.942	19.710
Valid N (listwise)	51				

Source: Author

Presented statistics indicate that observed countries strongly vary in each observed variable. Namely, in Chile, 32.50% of the population believe that science and technology are making their lives healthier, easier, and more comfortable, while in China, this portion rises to 81.1%. As expected, countries vary in their economic strength, measured by GDP per capita, ranging from Zimbabwe with the lowest and Singapore with the highest values. The percentage of females in the labour force, among other factors, is determined by the culture (Jaumotte, 2003; Tang and Cousins, 2005), and this variable also reflects differences between observed countries, whereas, in Iraq, this portion is 13.94% and is the highest in Armenia (52.65%). Ageing of society as a process observed on a national level is the most strongly expressed in Japan (with almost 30% of the population aged 65 and older). At the same time, this portion is significantly lower for underdeveloped countries, and Kenya has the lowest value of 2.84%. Regarding the number of individuals using the Internet, Ethiopia has the lowest percentage, and Malaysia has the highest, with over 96% of the population.

4. RESULTS AND DISCUSSION

Results on five selected variables indicate that attitudes towards science and technology should be observed along with other country-specific variables while estimating the potential of the social robot market in a specific country. Namely, countries belonging to Cluster 2 (Table 3) with the highest portion of the population with positive attitudes are unlikely to be an interesting market, at least at the observed time. At the same time, countries in Cluster 1, despite the worst result in attitudes toward science and technology, should be observed as a potential market to further develop and expand.

In other words, according to the obtained results (Table 3 and Table 4), even though the population in countries from Cluster 1 seems to be reserved towards science and technology, their other characteristics imply that they should be the focus while planning markets for social robots. Their wealth (measured by GDP pc), a portion of females in the labour market, the ageing problem and high Internet usage indicate they can afford and need social robots. This Cluster has a rather high number of countries (twelve, as seen in Table 5 indicating Euclidean distances), and they are developed countries whose partial scepticism towards science and technology might be justified by their awareness of the negative sides of technology (Bartneck, et al., 2005) since they have been using it in all spheres of their lives.

Table 3. Final Cluster Centers

	Cluster		
	1	**2**	**3**
Tech	51.04	56.29	55.30
GDPpc	48960.00	15015.84	118887.82
LabourF	46.12	38.14	42.88
Pop65	18.86	8.40	14.13
Internet	89.77	69.83	91.10

Source: Author

Table 4. Distances between Final Cluster Centers

Cluster	1	2	3
1		33944.164	69927.825
2	33944.164		103871.982
3	69927.825	103871.982	

Source: Author

On the other hand, Cluster 3 is more similar to Cluster 1 than Cluster 2 (Table 3 and Table 4) regarding observed characteristics of the labour market, ageing and Internet usage. However, Cluster 3 stands out regarding GDP per capita, and this, along with a rather high portion of the population agreeing that science and technology made their lives healthier, easier, and more comfortable, indicates that members of this cluster are highly developed, in a large extent, due to science and technology. Consequently, this cluster's countries will likely be a fruitful social robots market. However, as confirmed in Table 5, the number of countries with such characteristics is small, and in the analysed sample, solely Singapore belongs to Cluster 3.

Table 5. Cluster membership

Country	Cl.	Distance	Country	Cl.	Distance	Country	Cl.	Distance
Argentina	2	8738.539	Guatemala	2	5165	Nigeria	2	9583.942
Armenia	2	646.254	Indonesia	2	1929.491	Pakistan	2	9242.536
Australia	1	6987.059	Iran	2	1541.405	Peru	2	1185.429
Bangladesh	2	8493.38	Iraq	2	5320.334	Philippines	2	6082.744
Bolivia	2	6130.629	Japan	1	6126.163	Romania	1	12682.68
Brazil	2	1244.396	Jordan	2	4860.492	Russia	1	14916.7
Canada	1	4063.425	Kazakhstan	2	13796.06	Serbia	2	6631.514
Chile	2	13321.27	Kenya	2	9779.325	Singapore	3	0
China	2	4468.544	Lebanon	2	685.569	Slovakia	1	14431.34
Colombia	2	2089.182	Malaysia	2	14041.72	Thailand	2	3839.249
Cyprus	1	4554.992	Maldives	2	5690.835	Tunisia	2	3544.409
Czechia	1	3329.972	Mexico	2	4562.569	Turkey	2	15436.26
Ecuador	2	3243.395	Mongolia	2	2140.318	Ukraine	2	726.983
Egypt	2	1575.363	Morocco	2	6123.808	United States	1	21259.48
Ethiopia	2	12456.86	Netherlands	1	14409.03	Uruguay	2	10647.6
Germany	1	9838.941	New Zealand	1	516.218	Vietnam	2	3288.085
Greece	2	16278.97	Nicaragua	2	8734.948	Zimbabwe	2	12681.94

Source: Author
Note: "Cl." denotes Cluster.

Results of performed cluster analysis indicate that five selected variables can help estimate which countries are more likely to be or become a fertile social robots market. Most observed countries (38 out of 51) are underdeveloped countries with a young population and increasing Internet usage. Their attitudes toward science and technology are positive to a large extent since they are revealing their benefits to improve various segments of their lives. However, at the observed moment, these countries are unlikely to become target markets since their economic strength is rather low. I.e. their economic standard makes it unlikely that individuals could afford social robots. At the same time, social robot business usage might not be necessary due

to the large portion of the young population that makes sufficient labour supply (Betcherman, 2015; Raja Junankar, 2019).

Contrary to priory described countries, wealthy countries with positive attitudes toward science and technology are a fruitful market for social robots. Yet, there are not many countries with such characteristics. Hence, countries with rather strong economies, even if their attitudes toward science and technology might be less positive due to years of experience with technology and its various effects, should be the ones in focus while developing and expanding the social robots market. Namely, individuals in these countries are likely to afford social robots. At the same time, they might need them due to the large portion of females participating in the labour market and the ageing of society since females more often provide informal elderly care to family members (Chen, et al., 2017; Michaud, et al., 2010). Further, these two country-level characteristics indicate that these countries are more likely to have shortages in labour supply that could be resolved by using social robots. Consequently, the ageing of society as a process shared among many developed countries might be a key variable to observe while making projections about the social robots market.

The presented results cannot be directly compared since, as previously stated, there are no similar studies to the author's best knowledge. However, the results of a study related to cluster analysis, presented in Chapter 2 (López-Sánchez, et al., 2018), reveal that developed countries are significant in the market for industrial robots, with the highly developed countries standing out, which is in line with the results on social robots. Further, some of the developed countries belonging to Cluster 1 (e.g. Germany, the USA, Japan, etc.) are also often studied in research on culture-related perceptions and attitudes towards social robots (Fracasso, et al., 2022; Li, et al., 2019; Marchesi, et al., 2021; Kort, et al., 2021, Suwa, et al., 2020; etc.). Hence, even though the focus of the mentioned studies is different, their choice of sample countries, at least to some extent, confirms the obtained results.

5. CONCLUSION

The economic importance of the social robots market has been rising for years, and with technological progress, possibilities for their usage will rise as well. Consequently, social robots can be regarded as an investment opportunity, and it is beneficial to estimate which countries are more likely to become lucrative markets. On the other side, social robots can help diminish problems such as shortages in the labour market in the health industry. Still, at the same time, they might decrease demand for human labour (e.g. in the service industry), causing various economic and social repercussions. Therefore, this study is focused on predicting future demand for social robots, regarded on a country level.

The empirical analysis of 51 countries revealed that attitudes toward science and technology should not be used as a sole indicator of future strong demand for social robots. Namely, other country-level characteristics such as GDP pc, the share of females in the labour market, the possible ageing problem and Internet usage should be considered. In that sense, as expected, wealthy, highly developed countries with strong affection towards science and technology are most likely to become the main actors in the global social robots market. However, there is a small limited number of countries sharing similar characteristics. Hence, even if showing a certain restraint towards science and technology, developed countries are more likely to generate significant demand for social robots. In other words, the social robots markets are likely to be developed in countries with rather high GDP pc, large share of females in the labour

market, ageing problem and high Internet usage indicating stakeholders in these countries can afford and need social robots.

Obtained results, along with results of other studies on social robots, indicate that while developing, selling and implementing social robots, in order to optimise this process, each country's economic characteristics, as well as culture, should be considered. At the same time, observing from a macroeconomic perspective, respective characteristics might help estimate in which countries social robots can diminish or create labour market issues. However, this research has its shortcomings. First, due to data unavailability, analysed data refer to the year 2021, and results might differ if the newer data have been used. Further, since, to the author's best knowledge, there is no publicly available data on the number of sold social robots among countries over the year(s), a regression (panel) data analysis could not be performed. Therefore, a more detailed analysis of the impact of selected variables on the social robots market is not provided here. Consequently, further research on the subject will involve expanding the sample and adding new variables that reflect technological development regarding the usage of artificial intelligence. This will allow more precise estimates of countries that should be in focus while detecting a prosperous social robots market.

REFERENCES

[1] Bartneck, C.; Nomura, T.; Kanda, T.; Suzuki, T.; Kennsuke, K. (2005). Cultural Differences in Attitudes Towards Robots. In *Proceedings of the AISB Symposium on Robot Companions: Hard Problems And Open Challenges In Human-Robot Interaction*, pp 1-4, Hatfield.

[2] Betcherman, G. (2015). Labor Market Regulations: What do we know about their Impacts in Developing Countries? *The World Bank Research Observer*, 30(1), pp 124–153, 2015.

[3] Chen, C.; Hensel, L. B.; Duan, Y.; Ince, R. A. A.; Garrod, O. G. B.; Beskow, J.; Jack, R. E.;. Schyns, P. G. (2019). Equipping social robots with culturally-sensitive facial expressions of emotion using data-driven methods. In *14th IEEE International Conference on Automatic Face & Gesture Recognition*, pp 1–8, 2019.

[4] Chen, L.; Zhao, N.; Fan, H.; Coyte, P. C. (2017). Informal Care and Labor Market Outcomes: Evidence From Chinese Married Women. *Research on Aging*, 39(2), pp 345–371, 2017.

[5] Coeckelbergh, M. (2022). The Ubuntu Robot: Towards a Relational Conceptual Framework for Intercultural Robotics. *Science and Engineering Ethics*, 28(16), pp 1-15, 2022.

[6] Dobrosovestnova, A.; Hannibal, G.; Reinboth, T. (2022). Service robots for affective labor: a sociology of labor perspective. *AI & Society*, 37, pp 487–499, 2022.

[7] Forgas-Coll, S.; Huertas-Garcia, R.; Andriella, A. et al. (2022). How do Consumers' Gender and Rational Thinking Affect the Acceptance of Entertainment Social Robots? *International Journal of Social Robotics*, 14, pp 973–994, 2022.

[8] Fracasso, F.; Buchweitz, L.; Theil, A. et al. (2022). Social Robots Acceptance and Marketability in Italy and Germany: A Cross-National Study Focusing on Assisted Living for Older Adults. *International Journal of Social Robotics*, 14, pp 1463–1480, 2022.

[9] Gjaci, A.; Recchiuto, C. T.; Sgorbissa, A. (2022). Towards Culture-Aware Co-Speech Gestures for Social Robots. *International Journal of Social Robotics*, 14, pp 1493–1506, 2022.

[10] Heerink, M.; Kröse, B.; Evers, V. et al. (2010). Assessing Acceptance of Assistive Social

Agent Technology by Older Adults: the Almere Model. *International Journal of Social Robotics*, 2, pp 361–375, 2010.

[11] Jaumotte, F. (2003). Female Labour Force Participation: Past Trends and Main Determinants in OECD Countries. *OECD Working Paper No. 376*, downloaded: [July, 3rd 2023]

[12] Korn, O.; Akalin, N.; Gouveia, R.. (2021). Understanding Cultural Preferences for Social Robots: A Study in German and Arab Communities. ACM Transactions on Human-Robot Interaction, 10(2), pp 1–19, 2021.

[13] Li, H.; Milani, S.; Krishnamoorthy, V.; Lewis, M.; Sycara, K. (2019). Perceptions of Domestic Robots' Normative Behavior Across Cultures. In *Proceedings of the 2019 AAAI/ACM Conference on AI, Ethics, and Society; Association for Computing Machinery*, pp 345–351, 2019.

[14] Lim, V.; Rooksby, M.; Cross, E.S. (2021). Social Robots on a Global Stage: Establishing a Role for Culture During Human–Robot Interaction. *International Journal of Social Robotics*, 13, pp 1307–1333, 2021.

[15] López-Sánchez, J. I.; Arroyo-Barriguete, J. L.; Morales-Contreras, M. (2020). The Industrial Robot Evolution In The World. A First Dendrogram For A Cluster Analysis. *Inclusive Robotics For A Better Society, Biosystems & Biorobotics*, 25, pp 31-36, 2020.

[16] Lugrin, B.; Dippold, J.; Bergmann, K. (2018). Social Robots as a Means of Integration? An Explorative Acceptance Study considering Gender and Non-verbal Behaviour. In *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS),* pp 2026-2032, 2018.

[17] Marchesi S.; Roselli C.; Wykowska A. (2021). Cultural values, but not nationality, predict social inclusion of robots. In *13th Internal Conference on Social Robotics. Lecture Notes in Computer Science*, 13086, pp 48-57, 2021.

[18] Michaud, P.-C.; Heitmueller, A.; Nazarov, Z. (2010). A dynamic analysis of informal care and employment in England. *Labour Economics*, 17(3), pp 455-465, 2010.

[19] Mordor Intelligence, (2023). Social robots market size & share analysis – Growth trends & forecasts (2023 - 2028), https://www.mordorintelligence.com/industry-reports/social-robots-market, downloaded: [August, 25th, 2023]

[20] Pindyck, R. S.; Rubinfeld, D. L. (2013). Microeconomics - 8th ed., 2013, Prentice Hall

[21] Raja Junankar, P. N. (2019). Youth Labour Markets in Developing and Developed Countries: the Role of the Sectoral Composition of Production. *IZA Discussion Paper* No. 12256, http://dx.doi.org/10.2139/ssrn.3390246, downloaded: [August, 25th 2023]

[22] Sparrow, R. (2020). Robotics Has a Race Problem. *Science, Technology, & Human Values*, 45(3), pp 538–560, 2020.

[23] Suwa, S.; Tsujimura, M.; Kodate, N.; Donnelly, S.; Kitinoja, H.; Hallila, J.; Toivonen, M.; Ide, H.; Bergman-Kärpijoki, C.; Takahashi, E.; Ishimaru, M.; Shimamura, A.; Yu, W. (2020). Exploring perceptions toward home-care robots for older people in Finland, Ireland, and Japan: A comparative questionnaire studys. *Archives of Gerontology and Geriatrics*, 91, 104178, 2020.

[24] Tang, N.; Cousins, C. (2005). Working Time, Gender and Family: An East-West European Comparison. *Gender, Work & Organization*, 12, pp 527-550, 2005.

[25] The World Bank, (2023). World Development Indicators, https://databank.worldbank.org/source/world-development-indicators, downloaded: [June, 10th 2023]

[26] World Values Survey, (2023). Wave 7 (2017-2022), https://www.worldvaluessurvey.org/WVSDocumentationWV7.jsp, downloaded: [June, 10th 2023]

[27] Zrinjka, D.; Rosa, C.; Andrei, M. (2019). Robots in healthcare: a solution or a problem?, *Study for the Committee on Environment, Public Health, and Food Safety. Policy Department for Economic, Scientific and Quality of Life Policies*, https://www.europarl.europa.eu/RegData/etudes/IDAN/2019/638391/IPOL_IDA(2019)638391_EN.pdf, downloaded: [August, 24th 2023]

Original scientific paper / Izvorni znanstveni rad

OBILJEŽJA ULAGANJA INDIVIDUALNIH INVESTITORA NA FINANCIJSKOM TRŽIŠTU REPUBLIKE HRVATSKE: BIHEVIORALNI FAKTORI I USPJEŠNOST

DINA KORENT
Fakultet organizacije i informatike
Sveučilište u Zagrebu
Pavlinska 2, 42000 Varaždin, Hrvatska
dkorent@foi.unizg.hr

VLATKA KOLEMBUS
Fakultet organizacije i informatike
Sveučilište u Zagrebu
Pavlinska 2, 42000 Varaždin, Hrvatska
vkolembus@student.foi.hr

MARIJANA BUBANIĆ
Fakultet organizacije i informatike
Sveučilište u Zagrebu
Pavlinska 2, 42000 Varaždin, Hrvatska
mabubanic@foi.unizg.hr

SAŽETAK

Cilj rada je identificirati obilježja ulaganja individualnih investitora na financijskom tržištu Republike Hrvatske u domeni bihevioralnih faktora i uspješnosti. U radu se iznose postojeći teorijski i praktični aspekti bihevioralnih faktora i uspješnosti ulaganja na financijskim tržištima te rezultati njihova empirijskog istraživanja na dobrovoljnom uzorku individualnih investitora na financijskom tržištu Republike Hrvatske. U izradi rada koristila se znanstvena i stručna literatura područja te anketnim upitnikom prikupljeni primarni podaci. Pored općih znanstvenih metoda, osobito u empirijskom dijelu, koriste se metode deskriptivne statistike. Rezultati istraživanja otkrivaju da sve promatrane (pod)skupine bihevioralnih faktora u velikoj ili umjerenoj mjeri karakteriziraju ulaganja individualnih investitora na financijskom tržištu Republike Hrvatske te da oni svoja ulaganja pretežito smatraju uspješnima. Među prvima se napose ističu tržišni faktori, heuristike reprezentativnosti i sidrenja, a među fenomenima prospektne teorije averzija prema gubitku. Dodatno, obilježava ih lišenost efekta uokvirivanja, sklonost riziku, visoka razina samokontrole te nemali utjecaj ostalih bihevioralnih faktora. Percipirana uspješnost ulaganja je zadovoljavajuća s istaknutijom dimenzijom profitabilnosti u odnosu na sigurnost. Navedeno implicira i sugerira individualnim investitorima na financijskom tržištu Republike Hrvatske potrebu osvještavanja i adaptacije bihevioralnih faktora u smjeru njihova željenog potencijalnog utjecaja na uspješnost procesa i rezultata ulaganja.

KLJUČNE RIJEČI: obilježja ulaganja, bihevioralni faktori, uspješnost, individualni investitori, financijsko tržište, Republika Hrvatska

CHARACTERISTICS OF INDIVIDUAL INVESTORS' INVESTMENTS IN THE FINANCIAL MARKET OF THE REPUBLIC OF CROATIA: BEHAVIORAL FACTORS AND PERFORMANCE

ABSTRACT

The purpose of this paper is to identify the characteristics of individual investors' investments in the Republic of Croatia's financial market in terms of behavioral factors and performance. The paper discusses existing theoretical and practical features of behavioral factors and investment performance on financial markets, as well as the findings of their empirical research on a voluntary sample of individual investors on the Republic of Croatia's financial market. The paper was prepared using scientific and professional literature in the field, as well as primary data collected through a questionnaire. In addition to general scientific methods, descriptive statistics are used, particularly in the empirical the section. The research results reveal that all observed (sub)groups of behavioral factors to a large or moderate extent characterize the investments of individual investors on the financial market of the Republic of Croatia and that they mostly consider their investments to be successful. Among the first, market factors, heuristics of representativeness and anchoring stand out, and among the phenomena of prospect theory, loss aversion. In addition, they are characterized by the lack of framing effect, tendency to risk, high level of self-control and little influence of other behavioral factors. The perceived performance of the investment is satisfactory, with a more prominent dimension of profitability in relation to security. The preceding implies and suggests to individual investors on the Republic of Croatia's financial market the necessity for awareness and adaption of behavioral factors toward their intended potential influence on the performance of the investment process and results.

KEYWORDS: investment characteristics, behavioral factors, performance, individual investors, financial market, Republic of Croatia

1. UVOD

Ulaganje na financijskim tržištima je složen proces koji je određen brojnim faktorima, a koji posljedično uvjetuju i njegov krajnji ishod, odnosno uspješnost procesa i rezultata ulaganja [Pompian, 2006; Altman, 2013]. Faktori ulaganja i ostvarena uspješnost zajedno predstavljaju obilježja ulaganja. S obzirom na određenje navedenih obilježja literatura diferencira dva pristupa financijama: tradicionalni pristup i bihevioralni pristup. Tradicionalni neoklasični pristup financijama pretpostavlja da su investitori, tzv. *homo economicusi*, racionalni i neosjetljivi na unutarnje i vanjske faktore [Statman, 1995; Tseng, 2006], raspoložive su im sve relevantne, ispravne i cjelovite informacije koje omogućavaju procjenu i kontinuirano ažuriranje stvarnih vrijednosti vrijednosnih papira na osnovi kojih racionalni investitori donose investicijske odluke orijentirane maksimalizaciji vlastitih interesa [Korent i Kolembus, 2022]. Navedena obilježja tradicionalnih investitora rezultiraju pretpostavkom savršeno efikasnih financijskih tržišta [De Bondt et al., 2008]. Za razliku od tradicionalnog pristupa, prema bihevioralnom pristupu investitori su tzv. *homo sapiensi*, odnosno ograničene su racionalnosti i pod utjecajem brojnih unutarnjih i vanjskih faktora [Statman, 1995]. Njihovo okruženje u pravilu je neizvjesno, informacije nisu potpune te na njih utječu mnogi bihevioralni i drugi faktori koji uvjetuju da oni nisu bezuvjetno usmjereni maksimalizaciji

vlastitih interesa, već često pokušavaju zadovoljiti partikularne interese involviranih aktera na tržištima koja nisu savršeno efikasna [Korent i Kolembus, 2022]. U suglasju sa viđenjem bihevioralnog pristupa, može se ekstrahirati da tradicionalisti prikazuju djelovanja investitora onakvima kakva bi ona trebala biti, a bihevioristi, uvažavajući potonja, onakvima kakva ona uistinu jesu [De Bondt et al., 2008]. Drugim riječima, bihevioralni investitori nisu potpuna kontradikcija tradicionalnim investitorima, već njihova bihevioralna akomodacija uvjetima realnih, nesavršenih tržišta [Korent i Kolembus, 2022]. Bihevioralna prilagodba investitora manifestira se afirmacijom bihevioralnih faktora, odnosno njihovim korištenjem u cilju realizacije, iz njihove perspektive, uspješnih ulaganja.

Potonja problematika, napose zbog činjenice što anomalije na financijskim tržištima nadilaze objašnjenja tradicionalnog pristupa, pobuđuje zavidan interes istraživača koji se manifestira uzletom istraživanja bihevioralnih faktora i uspješnosti ulaganja, kao i njihova odnosa. Dok većina njih, u većoj ili manjoj mjeri, detektira egzistenciju bihevioralnih faktora, rezultati vezani za njihov utjecaj na uspješnost ulaganja su nedosljedni. [Fama, 1965; Olsen, 1998; Caparrelli et al., 2004; Waweru et al., 2008; Dash, 2010; Waruingi, 2011; Chaudhary, 2013; L. Kengatharan i N. Kengatharan, 2014; Ojwang, 2015; Jovanović, 2016; Mahmood, 2016; Shusha i Touny, 2016; Devi i Joseph, 2017; Zelić, 2017; Jokar i Daneshi, 2018; Sochi, 2018; Areiqat et al., 2019; Keswani et al., 2019; Ogunlusi i Obademi, 2019; Than, 2019; Baral i Pokharel, 2020; Elhussein i Abdelgadir, 2020; Huguru et al., 2020; Kiran i Sharma, 2021; Kunwar, 2021; Nareswari et al., 2021; Prasad et al., 2021; Rehan i Alvi, 2021; Silwal i Bajracharya, 2021; Yang et al., 2021; Hossain i Siddiqua, 2022; Natasya et al., 2022; Sabaawi i Alyouzbaky, 2022; Vuković, 2022; Brmalj, 2023; Yasmin i Ferdaous, 2023; između ostalih].

Iz postavljenog problema proizlazi cilj ovog rada, a on je istražiti obilježja ulaganja individualnih investitora na nedostatno istraženom financijskom tržištu Republike Hrvatske u domeni bihevioralnih faktora i uspješnosti. Navedeni su važni implikatori za investicijsku analizu i upravljanje portfeljem individualnih investitora, za menadžment burze i regulatore na financijskim tržištima općenito te na financijskom tržištu Republike Hrvatske specifično. Polazeći od navedenog, na temelju pregleda literature i podijeljenih spoznaja dosadašnjih istraživanja, postavljeno je sljedeće istraživačko pitanje: *Koja su obilježja ulaganja individualnih investitora na financijskom tržištu Republike Hrvatske u kontekstu bihevioralnih faktora i uspješnosti?* U pronalasku odgovora na postavljeno pitanje provedeno je teorijsko i praktično istraživanje predstavljeno u nastavku rada, koji je strukturiran kako slijedi. Produbljujući problematiku rada izloženu uvodno, u drugom se poglavlju elaboriraju teorijski i praktični aspekti bihevioralnih financija. Treće poglavlje predstavlja metodološki splet, a četvrto rezultate empirijske analize. Naposljetku, nakon rasprave u petom poglavlju, koja uključuje osvrte na rezultate, implikacije i znanstveni doprinos rada, šesto poglavlje zaključno sintetizira ključne spoznaje s očitovanjem o istraživačkom pitanju, ograničenja te preporuke za daljnja istraživanja.

2. TEORIJSKI I PRAKTIČNI ASPEKTI BIHEVIORALNIH FAKTORA I USPJEŠNOSTI ULAGANJA

Premda je bihevioralna komponenta oduvijek prisutna u ekonomiji [Brajović i Preša, 2015], bihevioralna ekonomija i bihevioralne financije, kao njen dio, su relativno novo područje koje se postepeno razvijalo i svoj procvat u znanstvenom, poslovnom i širem društvenom

kontekstu doživjelo 90-ih godina 20. stoljeća [Ricciardi i Simon, 2000; Shiller, 2005; Valsova, 2016]. Ono se razvilo uslijed ograničenja tradicionalnog neoklasičnog pristupa ekonomiji i financijama da objasni sve učestalije pojave devijacija od teorija i modela tradicionalnog pristupa [Nagy, 2017]. Navedeno područje, koje su utemeljili nobelovac Kahneman i Tversky, pritom ne osporava, već multidisciplinarnim tretmanom, koji nadograđuje stajališta kvantitativnih znanosti poput matematike i statistike inkorporiranjem psihologije, sociologije, antropologije i sličnih znanosti, adaptira i unaprjeđuje tradicionalni pristup [Ricciardi i Simon, 2010; Nagy, 2017]. Takav pristup smatra se svrsishodnijim u detekciji i objašnjenju uzroka, prirode i posljedica anomalija u smislu da u konačnici omogućava bolje predviđanje i poboljšanje procesa i rezultata ulaganja [Schinckus, 2011; Valsova, 2016; Nagy, 2017].

Spomenuti dvojac, kao i drugi pristaše bihevioralnog pristupa, učestale pojave anomalija pripisuju pristranostima u procesu ulaganja, napose u prosuđivanju i donošenju odluka, a koje su rezultat spleta različitih faktora [Valsova, 2016]. Premda je nemali broj autora klasificirao te faktore, u praksi je najkorištenija podjela na ekonomske i društvene faktore. Posljednji se, zbog identificiranog značajnog intenziteta, dalje dijele na opće i bihevioralne društvene faktore, a bihevioralni društveni faktori na heuristike, fenomene definirane teorijom očekivanog izbora, učinak krda i tržišne faktore. [Kengatharan i Kengatharan, 2014].

Heuristike, kognitivni prečaci ili takozvana pravila palca su pomoćna sredstva i tehnike koje investitorima omogućavaju donošenje odluka uz manji utrošak vremena, napora i financijskih sredstava [Polšek i Bovan, 2014], napose u situacijama tržišne neizvjesnosti [Tversky i Kahneman, 1974] i/ili u uvjetima nemogućnosti prikupljanja i ispravne obrade informacija [Mathews, 2013]. Iako su nerijetko korisne, heuristike mogu rezultirati kognitivnim pristranostima koje mogu rezultirati rješenjima koja nisu optimalna [Polšek i Bovan, 2014]. U literaturi se najčešće spominju sljedeće heuristike: heuristika raspoloživosti, heuristika reprezentativnosti, samouvjerenosti, heuristika sidrenja i prilagodbe, samouvjerenost i izbjegavanje kajanja (zabluda kockara) [Kengatharan i Kengatharan, 2014]. Heuristika raspoloživosti je sklonost korištenju informacija koje pojedincima brzo i lako padnu na pamet prilikom donošenja odluka, a primjer su preferencije ulaganja u lokalna poduzeća o kojima su informacije lako dostupne. Heuristika reprezentativnosti je uobičajena pogreška u obradi informacija kada pojedinac vjeruje da postoji veća korelacija između dva slična događaja nego što je to stvarno slučaj. Samouvjerenost je tendencija pogrešne i zavaravajuće procjene znanja i vještina boljima nego što zapravo jesu, što pojedince čini manje opreznima i sklonijima pogreškama pri donošenju odluka o ulaganjima. Heuristika sidrenja je kognitivni prečac, odnosno pristranost u kojoj na donošenje odluka pojedinaca utječe jedna točka uporišta, poznata kao referentna točka. Izbjegavanje kajanja je zabluda koja se događa kada pojedinac vjeruje da postoji manja ili veća vjerojatnost da će se određeni događaj dogoditi na temelju ishoda prethodnog niza događaja. [Silwal i Bajracharya, 2021]

Teorija očekivanog izbora, odnosno prospektna teorija koju su razvili Kahneman i Tversky (1979) deskriptivna je alternativa normativnoj teoriji očekivane korisnosti koja predstavlja temelj bihevioralnih financija [Brajković i Peša, 2015]. Simultano s heuristikama i ostalim bihevioralnim faktorima koji, između ostalog, opisuju i omogućavaju evaluaciju rizika, odnosno gubitaka i dobitaka, teorija očekivanih izbora opisuje donošenje odluka na osnovi potencijalnih vrijednosti gubitaka i dobitaka, a ne finalnog ishoda [Charles i Kasilingam, 2014]. Pritom ljudi diferentno evaluiraju dobitke i gubitke te svoje odluke temelje više na percipiranim dobitcima nego na percipiranim gubicima. Drugim riječima, između dva jednaka izbora, čak i istog finalnog ekonomskog rezultata, pri čemu je jedan izražen u terminima

percipiranih dobitaka, a drugi u terminima percipiranih gubitaka, ljudi odabiru prvi [Uzar i Akkaya, 2013] jer prema teoriji očekivanog izbora gubitak prouzrokuje više tuge nego što dobitak usrećuje [Singh, 2010; Taffler, 2014]. Shodno tome, ključni fenomeni te teorije su averzija prema gubitku, averzija prema žaljenju, mentalno računovodstvo, emocije i samokontrola te efekt uokvirivanja koji karakterizira prethodne fenomene i heuristike s popratnim kognitivnim pristranostima, determiniran individualnom tolerancijom na rizik i vrijednošću prinosa [Charles i Kasilingam, 2014]. Averzija prema gubitku govori da je osjećaj žaljenja zbog gubitka dvostruko jači nego osjećaj zadovoljstva zbog dobitka. Investitori se boje gubitaka pa su skloniji riskirati kako bi izbjegli gubitke nego kako bi ostvarili dobitke. Averzija prema žaljenju se odnosi na ljudsko ponašanje nakon što naprave grešku, što može narušiti racionalno ponašanje investitora uzrokujući ili nepotrebnu sklonost riziku ili motivaciju za nepromišljeno ulaganje. Tijekom produženih tržišta bikova, averzija prema žaljenju uzrokuje da neki investitori nastave snažno ulagati, ignorirajući znakove nadolazećeg pada. [Silwal i Bajracharya, 2021] Mentalno računovodstvo je tendencija investitora da izrade mentalnu procjenu ulaganja koja određuje izbor vrijednosnih papira i cijene imovine [Thaler, 1999; Brmalj, 2023]. Prema fenomenu mentalnog računovodstva investitori su skloni zadržati imovinu na kojoj su doživjeli gubitke, ali su skloni prodati imovinu u kojoj su uživali dobitke [Silwal i Bajracharya, 2021].

Dok heuristike i drugi bihevioralni faktori podržavaju definiranja cijena aktive, u fokusu prospektne teorije su bihevioralni procesi koji se odnose na portfelje [Brajković i Peša, 2015]. Bihevioralne procese uslijed ograničene racionalnosti, napose u situacijama neizvjesnosti popraćenim nedostatnim i/ili neodgovarajućim informacijama [Kundid Novokmet et al., 2021], bojazni od grešaka [Redhead, 2008] i/ili nastojanja za postizanjem socijalne prihvaćenosti [Phung, 2010] nerijetko karakterizira svjesna ili nesvjesna imitacija drugih [Kundid Novokmet et al., 2021]. Navedeni fenomen sljedbeništva poznat je kao efekt krda [Kengatharan i Kengatharan, 2014] i u praksi egzistira u dva oblika: namjerno i nenamjerno sljedbeništvo [Brajković i Peša, 2015]. Naposljetku, praksa svjedoči, a literatura prepoznaje i skupinu bihevioralnih faktora koji potječu s tržišta i stoga se nazivaju tržišnim faktorima te uključuju: promjene cijena, informacije s tržišta, prethodne trendove, preferencije potrošača te pretjerane reakcije potrošača [Kengatharan i Kengatharan, 2014].

Bihevioristi smatraju da izloženi bihevioralni društveni faktori, uz vlastite interese i očekivane ishode investitora te ostale faktore (ekonomske i opće društvene faktore), zajedno determiniraju uspješnost procesa i rezultata ulaganja [Kengatharan i Kengatharan, 2014]. U ovisnosti o kolektivnom utjecaju spleta potencijalnih utjecajnih faktora sam proces i rezultati ulaganja mogu biti u većoj ili manjoj mjeri uspješni, ovisno o razini usklađenosti realiziranih s očekivanim ishodima investitora. Mnogobrojna, ranije spomenuta, istraživanja doprinijela su razvoju i potvrdila navedena teorijska stajališta proizašla iz praktičnih indikacija da proces ulaganja investitora na financijskim tržištima obilježava postojanje bihevioralnih faktora te da postoji korelacija na relaciji faktori ─ pristranosti ─ anomalije ─ (ne)uspjeh procesa i rezultata ulaganja. Ponukano navedenim spoznajama, a s obzirom na njihovu nedostatnu verificiranost na financijskom tržištu Republike Hrvatske, provedeno je istraživanje u okviru ovog rada.

3. METODOLOŠKI SPLET

Kako bi se dao odgovor na postavljeno istraživačko pitanje provedeno je praktično istraživanje obilježja individualnih investitora na financijskom tržištu Republike Hrvatske u domeni bihevioralnih faktora i uspješnosti. Podaci su prikupljeni metodom ispitivanja, pri čemu je kao instrument istraživanja korišten anketni upitnik[1] izrađen u softveru Google Forms. Anketni upitnik obuhvatio je 51 pitanje i izjavu, derivirane iz dosadašnjih srodnih istraživanja prema principima njihove frekventnosti i signifikantnosti. Pitanja i izjave grupirane su u tri sekcije koje se za potrebe analize dalje dijele na skupine i podskupine. Prva sekcija sastoji se od pitanja i izjava (1 ─ 8) o demografskim i poslovnim obilježjima ispitanika (spol, dob, razina obrazovanja i bračni status te trajanje prisutnosti na Zagrebačkoj burzi (eng. Zagreb Stock Exchange, ZSE), područje djelovanja, pohađanja tečaja na ZSE, tip investitora) koja su formulirana kao pitanja s jednostrukim ili višestrukim odabirom. Pitanjima i izjavama u drugoj sekciji (9 ─ 44) ispituju se obilježja u pojedinim skupinama i podskupinama bihevioralnih faktora (heuristike i pristranosti: reprezentativnost, raspoloživost, sidrenje i prilagodba, samouvjerenost i izbjegavanje kajanja (zabluda kockara); teorija očekivanog izbora i pristranosti: averzija prema gubitku, averzija prema žaljenju, mentalno računovodstvo, emocije i samokontrola, uokvirivanje; efekt krda i tržišni faktori), a onima u trećoj sekciji (45 ─ 51) obilježja vezana za percipiranu uspješnost ulaganja ispitanika. Na pitanja i izjave u drugoj i trećoj sekciji ispitanici su odgovarali jednostrukim odabirom, pri čemu je jedno pitanje bilo u obliku pitanja s jednostrukim odgovorom, a sve preostale izjave u formi linearnog mjerila, odnosno Likertove skale od 1 (u potpunosti se ne slažem) do 5 (u potpunosti se slažem) na kojoj su ispitanici jednostrukim odabirom izražavali intenzitet (ne)slaganja s njima. Cronbach alpha koeficijenti pouzdanosti (pod)skupina bihevioralnih faktora i svih bihevioralnih faktora zajedno (Tablica 2) te uspješnosti (Tablica 3), izuzev za heuristiku reprezentativnosti (0,3477), heuristiku sidrenja i prilagodbe (0,5905), mentalno računovodstvo (0,4760), averziju prema žaljenju (0,5844) i emocije (0,5229) jednaki su ili viši od prihvatljive vrijednosti koja prema autorima Baral i Pokharel [2020] iznosi 0,6.

Statistički skup istraživanja su individualni investitori na financijskom tržištu Republike Hrvatske, odnosno Zagrebačkoj burzi. S obzirom na to da ne postoji njihov javno dostupan popis, do uzorka dobrovoljaca se došlo preko izdavatelja vrijednosnih papira kojima se trguje na Zagrebačkoj burzi čiji se popis nalazi na njezinim službenim stranicama. S obzirom na opreznost izdavatelja vezano za dijeljenje podataka svojih investitora, anketni je upitnik poslan na njihove e-mail adrese, a oni su ga na zahtjev autorica distribuirali individualnim investitorima koji trguju njihovim vrijednosnim papirima. Pored navedenog, kako bi se doprlo do ciljane populacije anketni upitnik je postavljen i na forum Dionice.NET koji navedenu okuplja. Poziv za ispunjavanje upitnika uključio je zamolbu za ispunjavanje, URL adresu upitnika, određenje teme, namjene i provoditelja istraživanja, definiranje karaktera ankete, procjene vremena potrebnog za ispunjavanje upitnika (10ak minuta), e-mail adresu za upite te zahvalu. U razdoblju od 28. ─ 15. 9. 2023. prikupljeno je ukupno 75 odgovora koji sačinjavaju uzorak. Prikupljeni odgovori analizirani su metodama deskriptivne statistike. Razine utjecaja bihevioralnih faktora na odluke o ulaganjima te razina uspješnosti ulaganja utvrđene su izračunavanjem prosječne vrijednosti svakog pojedinog faktora, (pod)skupina faktora i varijabli. Na Likertovoj skali od 5 stupnjeva, prema autorima Silwal i Bajracharya [2021] prosječne vrijednosti bihevioralnih faktora mogu odrediti njihov utjecaj na donošenje investicijskih odluka na sljedeći način: prosječne vrijednosti od 1 do 1,80 demonstriraju vrlo

[1] Dostupan na zahtjev.

nizak utjecaj, od 1,81 do 2,60 mali utjecaj, od 2,61 do 3,40 umjereni utjecaj, od 3,41 do 4,20 veliki utjecaj te od 4,21 do 5 vrlo veliki utjecaj.

4. REZULTATI

Poglavlje donosi prezentaciju i interpretaciju rezultata analize demografskih i poslovnih obilježja ispitanika te analize njihovih obilježja s aspekta bihevioralnih faktora i uspješnosti ulaganja.

4.1. DEMOGRAFSKA I POSLOVNA OBILJEŽJA INDIVIDUALNIH INVESTITORA NA FINANCIJSKOM TRŽIŠTU REPUBLIKE HRVATSKE

Demografska i poslovna obilježja ispitanika izložena su u Tablica 1 u prilozima rada. U kontekstu demografskih obilježja, među anketiranim individualnim investitorima prema spolu prevladavaju žene (58,7 %), prema dobi najzastupljenije su osobe od 26 ─ 35 godina (30,7 %) i 36 ─ 45 godina (29,3 %), prema razini obrazovanja osobe za završenim specijalističkim ili sveučilišnim diplomskim studijem (40,0 %), a prema bračnom statusu oženjeni odnosno udane osobe (60,0 %).

Poslovna obilježja otkrivaju da je većina ispitanika prisutna na hrvatskom financijskom tržištu više od 5 godina (53,3 %), 40,0 % njih u nekoj od djelatnosti koja se ne nalazi među ponuđenima, dok je među ponuđenim djelatnostima najčešća skupina pravnih, računovodstvenih, upravljačkih, arhitektonskih djelatnosti i inženjerstva te tehničkog ispitivanja i analize. Prevladavajući dio ispitanika izjasnio se da nije pohađao neki tečaj na hrvatskom financijskom tržištu (80,0 %) te da im je fokus ulaganja dugoročni, odnosno namjena ulaganja određena je postavljenim ciljevima ulaganja u dugom roku, očekujući primjerenu zaradu (50,7 %).

4.2. BIIHEVIORALNI FAKTORI ULAGANJA INDIVIDUALNIH INVESTITORA NA FINANCIJSKOM TRŽIŠTU REPUBLIKE HRVATSKE

Rezultati koji se odnose na bihevioralne faktore ulaganja ispitanika dani su u Tablica 2 u prilozima rada. Prosječne vrijednosti promatranih skupina bihevioralnih faktora sugeriraju da navedene imaju pretežito veliki utjecaj na donošenje odluka o ulaganjima. Specifično, ulaganja individualnih investitora na financijskom tržištu Republike Hrvatske u najvećoj su mjeri određena tržišnim faktorima (prosječna vrijednost: 4,06), iza kojih slijede heuristike (prosječna vrijednost: 3,63) i teorija očekivanog izbora (prosječna vrijednost: 3,50), te naposljetku efekt krda (prosječna vrijednost: 3,10). Pritom prve tri skupine demonstriraju veliki utjecaj na investicijske odluke, dok je utjecaj posljednje skupine umjeren. Među tržišnim faktorima najveći značaj imaju tržišne informacije (prosječna vrijednost: 4,17), zatim slijede promjene cijena (prosječna vrijednost: 4,11), i naposljetku prethodni trendovi na tržištu (prosječna vrijednost: 3,89), svi redom s velikim utjecajem na investicijske odluke. Naime, 78,7 % ispitanih smatra da su informacije o tržištu važne za njihova ulaganja u vrijednosne papire, 74,7 % njih se izjašnjava da pažljivo razmatra promjene cijena vrijednosnih papira u koje namjerava ulagati, a 69,3 % kod svojih budućih ulaganja uzima u obzir prošla kretanja vrijednosnih papira.

U spektru rezultata vezanih za heuristike ističe se samouvjerenost (prosječna vrijednost: 3,86), iza koje s približno jednakom važnosti slijedi heuristika reprezentativnosti (prosječna vrijednost: 3,84), nakon koje dolazi heuristika sidrenja i prilagodbe (prosječna vrijednost: 3,69) te na začelju heuristika raspoloživosti (prosječna vrijednost: 3,44) i izbjegavanje kajanja (prosječna vrijednost: 3,39). Dok prve četiri podskupine heuristika imaju veliki utjecaj na investicijske odluke, izbjegavanje kajanja je jedina među navedenim podskupinama heuristika koja granično iskazuje umjereni utjecaj. Prema rezultatima koji se odnose na samouvjerenost, 62,7% ispitanika vjeruje kako im vlastite vještine i znanja o financijskom tržištu mogu pomoći da nadmaše tržište te je 72 % onih koji su uvjereni u vlastito donošenje ispravne odluke o ulaganju. Relativno visoka prosječna vrijednost prisutnosti heuristike reprezentativnosti određena je prije svega visokom relativnom frekvencijom ispitanika koji izbjegavaju ulagati u poduzeća s lošom poviješću (70,7 %) i onih čija prošlost utječe na njihove sadašnje odluke (68,0 %), a nešto manje korištenjem analize trendova nekih reprezentativnih vrijednosnih papira kako bi se donijela odluka o investiranju (53,4 %). Intenzitetu utjecaja heuristike sidrenja i prilagodbe najviše doprinosi činjenica što se čak 77,3 % ispitanih individualnih investitora prilikom poduzimanja sljedeće investicije oslanja na svoja prethodna iskustva na tržištu, dok 58,7 % njih pokušava procijeniti promjene cijena vrijednosnih papira u budućnosti na temelju njihovih trenutnih cijena, a 42,7 % ih kupuje „vruće“ vrijednosne papire i izbjegava one koji su u nedavnoj prošlosti imali loše rezultate. S aspekta heuristike raspoloživosti 62,7 % ispitanika smatra da investitori preferiraju lokalna tržišta u odnosu na međunarodna jer su upućeniji u zbivanja na prvom, a nešto više od pola njih (52 %) radije kupuje lokalne vrijednosne papire nego međunarodne jer su informacije o lokalnim vrijednosnim papirima dostupnije. Zanimljivo, samo će se 33,3 % ispitanika prilikom donošenja odluke o kupnji vrijednosnih papira u određenom poduzeću osloniti na informacije prikupljene od kolega. Konačno, izbjegavanje kajanja (zabluda kockara) je heuristika koja u najmanjoj mjeri obilježava ulaganja ispitanika. Naime, dok s jedne strane polovica njih (50,7 %) smatra da su stanju predvidjeti dobar i loš rezultat te poduzeti optimalne investicije, s druge strane 54,7 % ih se niti slaže niti ne slaže da obično mogu predvidjeti kraj dobrih ili loših tržišnih prinosa na financijskom tržištu Republike Hrvatske. Nešto manje od polovice ispitanika (48,0 %) predviđa promjene cijena vrijednosnih papira u budućnosti na temelju nedavnih kretanja njihovih cijena.

Odgovori ispitanika na izjave relevantne za detekciju fenomena teorije očekivanih izbora ukazuju da među njima njihova ulaganja najviše karakterizira fenomen averzije prema gubitku (prosječna vrijednost: 3,66), potom averzija prema žaljenju (prosječna vrijednost: 3,50) i konačno mentalno računovodstvo (prosječna vrijednost: 3,35). Pritom se utjecaj prva dva fenomena ocjenjuje velikim, a trećeg umjerenim. Averzija ispitanika prema gubitka manifestira se sklonošću izbjegavanju investiranja u vrijednosne papire koji su nepredvidljivi koju izražava 65,4 % ispitanika, osjećajem nervoze kada cijene vrijednosnih papira u koje ulažu snažno padnu koju osjeća 61,3 % ispitanih, većom zabrinutošću zbog velikog gubitka vrijednosti njihovih vrijednosnih papira nego zbog propuštanja značajnog dobitka te povećanjem nesklonosti prema riziku nakon susreta s velikim gubitkom njihovih ulaganja prisutnima kod po 56 % ispitanika. Nadalje, u duhu averzije prema žaljenju konzistentno se oko polovice ispitanika izjašnjava da izbjegava prodaju vrijednosnih papira kojima je vrijednost pala i rado prodaje vrijednosne papire kojima je vrijednost porasla (53,4 %), da su skloni čuvanju vrijednosnih papira koji gube vrijednost čekajući bolja vremena (52,0 %) te da su više uznemireni zbog predugog držanja vrijednosnih papira koji donose gubitke nego zbog prerane prodaje vrijednosnih papira koji donose dobitke (46,7 %). Naposljetku, rezultati vezani za korištenje mentalnog računovodstva su podijeljeni, otkrivajući u jednu ruku sklonost zasebnog tretiranja svakog elementa investicijskog portfelja (61,3 %) i različitog

vrednovanja zarađenog novca i novca dobivenog na igrama na sreću (50,6 %), a u drugu ruku indiferentnost vezanu za zanemarivanje veze između različitih mogućnosti ulaganja (40,0 % se niti slaže niti ne slaže) i veću zabrinutost za učinak svakog vrijednosnog papira pojedinačno nego za portfelj u cjelini (53,3 % se niti slaže niti ne slaže).

Umjereni utjecaj mentalnog računovodstva prati uključenost emocija pri ulaganju s prosječnom vrijednosti od 3,39 i oprečnim mišljenjima ispitanika o utjecaju emocija na formiranje njihovih stavova prilikom investiranja (32,0 % se ne slaže, a 30,6 % slaže), usprkos prilično koherentnim stavovima da je emocionalna inteligencija važna karakteristika investitora (61,3 %). Nasuprot oprečju u stavovima o prisutnosti emocija pri ulaganju, stavovi ispitanika o samokontroli pretežito su jedinstveni. Čak 72,0 % ispitanih pažljivo promatra svoje investicije i ima visoku razinu kontrole nad investicijskim odlukama.

Kako bi se detektirala prisutnost uokvirivanja, od ispitanika se u dva navrata tražilo da zamisle istu situaciju, da se pojavila smrtonosna bolest koja će odnijeti oko 600 života, pri čemu su opcije ishoda, premda suštinski jednake, različito uokvirene u prvom odnosno drugom navratu. U oba je navrata približno isti dio ispitanika izabrao prvu, odnosno nerizičnu opciju (32,0 % i 30,7 %) te drugu, odnosno rizičnu opciju (68,0 % i 69,3 %). Odabir druge, rizične opcije u oba navrata ukazuje na to da su ispitanici konzistentno skloni riziku neovisno o okviru, odnosno da i u zoni dobitka i u zoni gubitka djeluju na istovjetan način.

Na kraju, najniža prosječna vrijednost raširenosti efekta krda (3,10), koja sugerira na njegov umjereni utjecaj na investicijske odluke, proizlazi iz dosljedne ravnodušnosti ispitanika da brzo reagiraju na promjene drugih investitora i prate njihove reakcije na tržištu (45,3 %) te da svoje investicijske odluke donose pod utjecajem odluka drugih investitora o odabiru vrsta vrijednosnih papira (45,3 %) i o obujmu investiranja u vrijednosne papire (41,3 %).

4.3. USPJEŠNOST ULAGANJA INDIVIDUALNIH INVESTITORA NA FINANCIJSKOM TRŽIŠTU REPUBLIKE HRVATSKE

Tablica 3. u prilozima rada prikazuje rezultate koji se referiraju na uspješnost ulaganja ispitanika. Sveukupno promatrano, na Likertovoj skali od 1 ─ 5 ispitanici svoju uspješnost ulaganja ocjenjuju prosječnom ocjenom od 3,78. Pritom u prosjeku smatraju da njihova ulaganja pokazuju bolje rezultate od očekivanih (prosječna vrijednost: 3,77) te osjećaju zadovoljstvo svojim investicijskim odlukama u prošloj godini (uključujući kupnju, prodaju, odabir vrsta i obujma vrijednosnih papira) (prosječna vrijednost: 3,99).

Dekompozicija rezultata o uspješnosti ulaganja na temeljne financijske koncepte: profitabilnost, odnosno prinos i rizik ostvarivanja te profitabilnosti, demonstrira da ulaganja individualnih investitora na financijskom tržištu Republike Hrvatske u većoj mjeri karakterizira profitabilnost, promatrana u kontekstu doprinosa povećanju novčanih tokova investitora u posljednjih pet godina i ostvarenja stope prinosa na razini ili iznad prosječne stope prinosa na tržištu (prosječna vrijednost: 3,85), nego sigurnost, odnosno manji rizik u odnosu na tržište (prosječna vrijednost: 3,51).

5. RASPRAVA

Rezultati provedenog empirijskog istraživanja indiciraju da ulaganja individualnih investitora na financijskom tržištu Republike Hrvatske obilježava velik utjecaj svih promatranih skupina bihevioralnih faktora (heuristika i pristranosti, teorije očekivanog izbora i tržišnih faktora) izuzev efekta krda, i relativno velika percipirana uspješnost ulaganja s izraženijom dimenzijom profitabilnosti nego sigurnosti. Veliki utjecaj bihevioralnih faktora s jedne strane, te zadovoljavajuća percipirana uspješnost ulaganja s druge strane, bez ulaženja u dublje analize, uvažavajući kretanja na hrvatskom financijskom tržištu, s mjerom opreza provocira tezu o zbirno pozitivnom utjecaju bihevioralnih faktora na uspješnost ulaganja.

Činjenica da najvišu prosječnu ocjenu imaju tržišni faktori, a među njima tržišne informacije, uz velike utjecaje i preostalih faktora (razmatranja promjena cijena, uzimanja u obzir tržišnih informacija i ekstrapolacije prošlih trendova), sugerira da investitori svoje investicijske odluke u najvećoj mjeri temelje upravo na njima. Heurističko ponašanje poput pretjerane samouvjerenosti, reprezentativnosti, sidrenja i prilagodbe te raspoloživosti, također, ima veliki utjecaj na odluke o ulaganjima individualnih investitora na financijskom tržištu Republike Hrvatske. Naime, uslijed nedostatka odgovarajućih i/ili pravovremenih informacija, investitori se oslanjanju na vlastite sposobnosti u previđanju kretanja tržišnih cijena te svoje odluke temelje na pretpostavljenoj korelaciji između prošlih i sadašnjih investicijskih odluka, svojevrsnim uporištima utjelovljenim u prethodnim tržišnim iskustvima, aktualnim i prošlim cijenama i rezultatima vrijednosnih papira, te na temelju informacija koje su im lakše dostupne. Ulaganja investitora karakterizira i umjeren utjecaj zablude kockara, odnosno vjerovanja u mogućnost procjene vjerojatnosti budućih događaja na temelju ishoda prethodnog niza događaja. Nadalje, utvrđeno je da individualni investitori na financijskom tržištu Republike Hrvatske, sukladno teoriji očekivanog izbora, pokazuju veliku averziju prema gubitku i averziju prema žaljenju te umjereno koriste mentalno računovodstvo. Pritom se averzija prema gubitku manifestira u manjoj sklonosti riziku uslijed nepredvidljivosti i nakon gubitka te jačim emocijama (nervoza, zabrinutost) koje gubitak izaziva u odnosu na dobitak. Potonje izvjesno implicira da se hrvatski individualni investitori više štite od potencijalnih gubitaka i moguće štete, nego što jure za dobicima. Isto tako, investitori, u suglasju s averzijom prema žaljenju imaju veliku tendenciju prerano prodati dobre vrijednosne papire i predugo držati vrijednosne papire s lošim rezultatima, dok su s aspekta rezultata prisutnosti fenomena mentalnog računovodstva, uslijed nesavršenih informacija, umjereno skloni razdvajati odluke o ulaganju i ignorirati međuovisnost tih odluka. Premda emocije umjereno obilježavaju proces donošenja odluka promatranih individualnih investitora, samokontrola je izraženo prisutna. Za razliku od navedenog, investitori su neovisno o okviru skloni riziku, odnosno nisu podložni uokvirivanju. Konačno, s obzirom na to da individualni investitori imaju tendenciju ponašati se sljedbenički, prateći odluke velike grupe trgovaca vrijednosnim papirima, ograničeni utjecaj efekta stada među ispitanim investitorima potencijalno odražava usku aktivnost burzovnog trgovanja na financijskom tržištu Republike Hrvatske.

Izloženi rezultati istraživanja pretežito su koherentni s rezultatima istraživanja koje su u različitim zemljama, između ostalih, proveli Kengatharan i Kengatharan [2014], Ojwang [2015]. Mahmood et al. [2016], Kiogothe [2017], Sochi [2018], Ogunlusi i Obademi [2019],

Elhussein i Abdelgadir [2020], Baral i Pokharel [2020], Hunguru et al. [2020], Sattar et al. [2020], Prasad et al. [2021], Rehan et al. [2021], Silwal i Bajracharya [2021] i Korent i Kolembus [2022] između ostalih. Iako se rezultati uvelike podudaraju u intenzitetu utjecaja pojedinih skupina bihevioralnih faktora i percipirane uspješnosti ulaganja, na razini podskupina utjecaj pojedinih bihevioralnih faktora na proces donošenja odluka o ulaganju diferentan je u ovisnosti o tržištu, odnosno gospodarstvu. Općenito, nalazi pružaju argumente da bihevioralne anomalije koje dovode do bihevioralnih pristranosti prevladavaju među individualnim investitorima na financijskom tržištu Republike Hrvatske, što ih čini pristranima i iracionalnima u procesu donošenja investicijskih odluka. Egzistencija snažnog bihevioralnog aspekta, usprkos percipiranoj uspješnosti ulaganja investitora, u izostanku istraživanja njihova odnosa, ultimativno dovodi u pitanje informacijsku i operativnu efikasnost hrvatskog financijskog tržišta, što je razvidno u njegovim volatilnim pokazateljima uspješnosti. Upravo iz tog razloga ishodi ovog rada imaju bitne implikacije za investitore, menadžment burze i regulatore. Povećanje racionalnosti investicijskih odluka sa konačnom svrhom poboljšanja efikasnosti tržišta u prvom redu traži povećanje svijesti o bihevioralnim anomalijama i pristranostima te njihovom utjecaju na investicijske odluke kroz poboljšanje obrazovanja i poslovne edukacije koje će u financijske teme integrirati psihologiju investitora. U drugom redu, individualne investitore valja poticati i omogućiti im korištenje usluga stručnjaka i brokera za upravljanje njihovim ulaganjima. U tom kontekstu, nastojanja menadžmenta burze trebala bi biti usmjerena poboljšanju kvalitete financijskih usluga brokerskih društava, također kroz prizmu tečajeva koje osvještavaju predmetne teme te posljedično oslobađaju stručnjake bihevioralnih pristranosti i facilitiraju donošenje racionalnih odluka o ulaganjima za njihove klijente. Naposljetku, povoljno okruženje zahtijeva od regulatora poduzimanje aktivnosti koje su fokusirane osiguranju lake dostupnosti odgovarajućih i pravovremenih informacija, pretpostavljajući provedivost zahtjeva za objavljivanje potpunih kvantitativnih i kvalitativnih informacija o društvima koja kotiraju na burzi te praćenje obrazaca trgovanja investitora.

Vezano za praćenje obrazaca donošenja investicijskih odluka, znanstveni doprinos rada očituje se u anketnom upitniku dizajniranom na temelju dosadašnjih relevantnih istraživanja i mogućnosti usporedbe njihovih rezultata s rezultatima predmetnog istraživanja, te u činjenici da je ovo jedno od rijetkih istraživanja u Republici Hrvatskoj koje istražuje obilježja ulaganja individualnih investitora kroz prizmu cjelovitog spleta bihevioralnih faktora i uspješnosti ulaganja, za razliku od dosadašnjih istraživanja koja su promatrala institucionalne investitore ili studente (često u diplomskim i srodnim radovima) ili su se fokusirala na određene (pod)skupine bihevioralnih faktora. Praktičan doprinos rada je u podizanju svijesti svih sudionika financijskih tržišta, ali i šire zajednice, o bihevioralnim obilježjima i obilježjima uspješnosti ulaganja individualnih investitora na financijskom tržištu Republike Hrvatske te u pružanju uvida u razumijevanje utjecaja bihevioralnih faktora na uspješnost ulaganja.

6. ZAKLJUČCI

Premda je racionalno donošenje investicijskih odluka pretpostavka perzistencije ulaganja, u praksi na donošenje odluka o ulaganjima utječu bihevioralni faktori koji su u velikoj ili rjeđe umjerenoj mjeri, premda ne potpuno, u kontradikciji s temeljenim principima tradicionalnih financijskih modela. Cilj ovog rada bio je istražiti obilježja ulaganja individualnih investitora

na nedostatno istraženom financijskom tržištu Republike Hrvatske u domeni bihevioralnih faktora i uspješnosti kao implikatora za praksu. U skladu s navedenim, u radu je deskriptivnom statistikom odgovora na pitanja i izjave iz anketnog upitnika pronađen odgovor na postavljeno istraživačko pitanje: *Koja su obilježja ulaganja individualnih investitora na financijskom tržištu Republike Hrvatske u kontekstu bihevioralnih faktora i uspješnosti?* Konzistentno s dijelom istraživanja sa sličnih tržišta, predmetno je istraživanje identificiralo da sve promatrane (pod)skupine bihevioralnih faktora i uspješnost u određenoj mjeri obilježavaju ulaganja hrvatskih individualnih investitora. Pritom su među skupinama bihevioralnih faktora najznačajnijima ocijenjeni tržišni faktori, a najmanje važnim efekt krda. Razine utjecaja na razini podskupina bihevioralnih faktora otkrivaju da su individualni investitori na financijskom tržištu Republike Hrvatske najviše pod utjecajem tržišnih informacija i prethodnih trendova na tržištu, samouvjereni su po pitanju svojih ulaganja, izraženo su podložni djelovanju heuristike reprezentativnosti i heuristike sidrenja te imaju naglašenu averziju prema gubitku. Uz to karakterizira ih odsutnost efekta uokvirivanja i sklonost riziku, ali i visoka razina samokontrole te nezanemariv utjecaj preostalih bihevioralnih faktora na donošenje investicijskih odluka. Percipirana uspješnost ulaganja je zadovoljavajuća s istaknutijim obilježjem profitabilnosti u odnosu na sigurnost.

Istraživanje rasvjetljava obilježja u domeni bihevioralnih faktora i ona vezana za uspješnost ulaganja te na taj način, s jedne strane, omogućava povećanje racionalnosti i efikasnosti, a s druge strane, shodno rezultatima, provocira pitanje o pozitivnom utjecaju bihevioralnih faktora na uspješnost ulaganja. Međutim, uslijed neispitivanja tog utjecaja, valja biti oprezan u tumačenju posljedica snažne bihevioralne komponente na tržišnu efikasnost, osobito uzmu li se u obzir performanse financijskog tržišta Republike Hrvatske. Navedeno imputira ograničenja ovog istraživanja koja se mogu sažeti u: zadržavanju na isključivo deskriptivnoj statističkoj analizi koja ne omogućava detekciju uzročno-posljedičnih veza i izvođenje utemeljenih i korisnijih zaključaka, veličini uzorka i nemogućnosti generalizacije rezultata te nepouzdanosti nekih čestica anketnog upitnika. U nastojanju amortizacije ili anuliranja spomenutih ograničenja, daljnja bi istraživanja trebalo provesti primjenom inferencijalne statistike na većim i, s aspekta kulturnih, financijskih i gospodarskih razlika, diverzificiranijim uzorcima uporabom potencijalno redefiniranog anketnog upitnika. Sugestija je provesti i komparativnu analizu bihevioralnih faktora i njihova utjecaja na proces i uspješnost ulaganja između individualnih i institucionalnih investitora.

REFERENCE

[1] Altman, M. (2013). What Behavioural Economics Has to Say about Financial Literacy, *Applied finance letters,* 2 (1), str. 12─17.

[2] Areiqat, A. Y.; Abu-Rumman, A.; Al-Alani, Y. S.; Alhorani, A. (2019). Impact of Behavioral Finance on Stock Investment Decisions Applied Study on a Sample of Investors at Amman Stock Exchange, *Academy of Accounting and Financial Studies Journal*, 23 (2), str. 1─17.

[3] Baral, S.; Pokharel, P. R. (2020). Behavioral factors and investment decision: A case of Nepal. https://www.zbw.eu/econis-archiv/bitstream/11159/449610/1/EBP076531902_0.pdf, preuzeto: [1. rujan 2023.].

[4] Brajković, A.; Radman Peša, A. (2015). Bihevioralne financije i teorija „ Crnog labuda". *Oeconomica Jadertina*, 5 (1), str. 65–93.

[5] Brmalj, N. (2023). *Utjecaj bihevioralnih faktora na donošenje investicijskih odluka* (Doktorski rad). Fakultet za menadžment u turizmu i ugostiteljstvu, Opatija, Sveučilište u Rijeci.
[6] Charles, A.; Kasilingam, R. (2014). Do Framing Effects of Investors Determine their Investment Personality? *Anvesha*, 7 (2), str. 38─45
[7] Chaudhary, A. K. (2013). Impact of behavioral finance in investment decisions and strategies: a fresh approach. *International Journal of Management Research and Business Strategy*, 2 (2), str. 66–83.
[8] Caparrelli, F.; D'Arcangelis, A. M.; Cassuto, A. (2004). Herding in the Italian Stock Market: A Case of Behavioral Finance. *Journal of Behavioral Finance,*, 5 (4), str. 222–230.
[9] Dash, M. K. (2010). Factors influencing investment decision of generations in India: An econometric study. *Int. J. Buss. Mgt. Eco. Res*, 1 (1), str. 15─26.
[10] De Bondt, W. F.; Thaler, R. (1985). Does the Stock Market Overreact?, *The Journal of Finance*, 40 (3), str. 793–805.
[11] Devi, N. N.; Joseph, A. V. (2017). Impact of demographic factors on Mutual fund Individual Investors‟ investment behavior. *International Journal for Research in Engineering Application & Management*, 3 (7), str. 36-45.
[12] Elhussein, N. H. A; Abdelgadir, J. N. A. (2020). Behavioral bias in individual investment decisions: Is it a common phenomenon in stock markets. International Journal of Financial Research, 11 (6), 25─36.
[13] Fama, E. F. (1965). The behavior of stock-market prices Related papers A Test of t he St able and Mixt ure of Normals Hypot heses for Int ernat ional St ock Ret urns The Behavior of Stock-Market Prices. *The Journal of Business*, 38 (1), str. 34–105.
[14] Hossain, T.; Siddiqua, P. (2022). Exploring the influence of behavioral aspects on stock investment decision-making. *PSU Research Review: An International Interdisciplinary Journal*, str. 2399–1747.
[15] Hunguru, P.; Sibanda, V.; Tadu, R. (2020). Determinants of Investment Decisions: A Study of Individual Investors on the Zimbabwe Stock Exchange. Applied Economics and Finance, 7 (5), str. 38-53.
[16] Jokar, H.; Daneshi, V. (2018). The impact of investors' behavior and managers' overconfidence on stock return: Evidence from Iran. *Cogent Business & Management*, 5 (1), 1559716.
[17] Jovanović, N. (2016). *Bihevioralna ekonomija i ponašanje potrošača* (Diplomski rad). Odjel za ekonomiju, Diplomski sveučilišni studij menadžmenta, Zadar, Sveučilište u Zadru.
[18] Kahneman, D.; Tversky, A. (1979) Prospect theory: an analysis of decision - making under risk. *Journal of Econometrica*, 47 (2), str. 263-291.
[19] Kengatharan, L.; Kengatharan, N. (2014). The Influence of Behavioral Factors in Making Investment Decisions and Performance: Study on Investors of Colombo Stock Exchange, Sri Lanka. *Asian Journal of Finance & Accounting*, 6 (1), str. 1─23.
[20] Keswani, S.; Dhingra, V.; Wadhwa, B. (2019). Impact of behavioral factors in making investment decisions and performance: study on investors of National Stock Exchange. *International Journal of Economics and Finance*, 11 (8), str. 80-90.
[21] Kiogothe, N. W. (2017). *Effect of behavioral factors on investment decisions of individual mutual fund investors in Kenya: a survey of individual mutual fund investors in Nairobi county* (Master thesis). School of Business and Public Management, Nairobi, KCA University.
[22] Korent, D.; Kolembus, V. (2022). The Behavior of Institutional Investors on The Croatian Financial Market: A Study at The Zagreb Stock Exchange. Proceedings of the

40th International Business Information Management Association (IBIMA), str. 884─899, Seville, Spain.
[23] Kundid Novokmet, A.; Jug, D.; Akrap, P. (2021): BEHAVIOURAL BIASES AND RISK PROPENSITY OF CROATIAN CITIZENS IN THE CORONAVIRUS CRISIS. *Proceedings of FEB Zagreb International Odyssey Conference on Economics and Business*, 3 (1), str. 634─660.
[24] Kunwar, K. (2021). The Relationship of Behavioral Factors with Investment Performance of Individual Investors in the Nepali Stock Market. *Prithvi Academic Journal*, 4 (May 2021), str. 66─83.
[25] Mahmood, Z.; Kouser, R.; Abbas, S. S.; Saba, I. (2016). The effect of hueristics, prospect and herding factors on investment performance. *Pakistan Journal of Social Sciences*, 36 (1), str. 475─484.
[26] Mathews, J. (2013). *Behavioral Finance: A Primary Analysis*. SSRN Eletronic Journal, https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2329573, preuzeto: [20. kolovoz 2023.].
[27] Nagy, J. L. (2017). *Behavioral Economics and the Effects of Psychology on the Stock Market*. *Applied Economics Theses*. 24, Buffalo State College. State University of New York, https://digitalcommons.buffalostate.edu/economics_theses/24, preuzeto: [17. kolovoz 2023.].
[28] Nareswari, N.; Balqista, A. S.; Negoro, N. P. (2021). *The Impact of Behavioral Aspects on Investment Decision Making*. Jurnal Manajemen dan Keuangan, 10 (1), str. 15─27.
[29] Natasya, N.; Kusumastuti, D. H.; Alifia, W.; Leon, F. M. (2022). The effect between behavioral biases and investment decisions moderated by financial literacy on the millennial generation in Jakarta. *The Accounting Journal of Binaniaga*, 7 (1), str. 113-126.
[30] Ogunlusi, O. E.; Obademi, O. (2021). The Impact of behavioural finance on investment decision-making: A study of selected investment banks in Nigeria. *Global Business Review*, 22 (6), str. 1345-1361.
[31] Ojwang, P. O. (2015). *Behavioral Factors and Investment Decisions by Traders in Kibuye Market, Kisumu Town, Kenya* (Master thesis). School of Business, Faculty of Business and Management Sciences, Nairobi, University of Nairobi.
[32] Olsen, R. A. (1998). Behavioral Finance and Its Implications for Stock-Price Volatility. *Financial Analysts Journal*,, 54 (2), str. 10–18.
[33] Phung, A. (2010). *Behavioral Finance*. http://i.investopedia.com/inv/pdf/tutorials/BehavioralFinance.pdf, preuzeto: [20. srpanj 2023.].
[34] Polšek, D.; Bovan, K., (2014). *Uvod u bihevioralnu ekonomiju*, Zagreb: Institut društvenih znanosti Ivo Pilar.
[35] Pompian, M. M.; Wood, A. S. (2006). *Behavioral Finance and Wealth Management: How to Build Optimal Portfolios for Private Clients*. New Jersey: John Wiley and Sons, Inc.
[36] Prasad, S.; Kiran, R.; Sharma, R. K. (2021). Behavioural, Socio-economic Factors, Financial Literacy and Investment Decisions: Are Men More Rational and Women More Emotional?. *The Indian Economic Journal, 69* (1), str. 66─87.
[37] Redhead, K. (2008*). Personal Finance and Investments: A Behavioural Finance Perspective (1st ed.).* London and New York: Routledge Taylor & Francis Group.
[38] Ricciardi, V.; Simon, H. K. (2000). What is Behavioral Finance? *Business, Education & Technology Journal*, 2 (2), str. 1─9.

[39] Al-Sabaawi, M. Y. M.; Alyouzbaky, B. A. (2022). The Impact of Information Technology Infrastructure Flexibility and Behavioral Biases on Investment Decision Making. *International Journal of Enterprise Information Systems (IJEIS)*, 18 (1), 1-22.
[40] Schinckus, C. (2011). Archeology of Behavioral Finance. *IUP Journal of Behavioral Finance*, 8 (2), str. 8─22.
[41] Shiller, R. J. (2005). Behavioral economics and institutional innovation. *Southern Economic Journal*, 72(2), str. 269─283.
[42] Shusha, A. A.; Touny, M. A. (2016). The attitudinal determinants of adopting the herd behavior: an applied study on the Egyptian exchange. *Journal of Finance and Investment Analysis*, 5 (1), str. 55─69.
[43] Silwal, P. P.; Bajracharya, S. (2021). Behavioral factors influencing stock investment decision of individuals. *The International Research Journal of Management Science*, 6 (1), str. 53─73.
[44] Singh, R. (2010). Behavıoural Fınance Studıes: Emergence and Developments. *Journal of Contemporary Management Research*, 4 (2), str. 2-3.
[45] Sochi, M. H. (2018). Behavioral factors influencing investment decision of the retail investors of Dhaka stock exchange: an empirical study. *The Cost and Management*, 46 (1), str. 20─29.
[46] Statman, M. (1995). Behavioral Finance versus Standard Finance. *AIMR Conference Proceedings*, 7, str. 14─22.
[47] Taffler, R. (2014). Emotional finance: theory and application. *Warwick Business School*, 14, https://www.efmaefm.org/0EFMAMEETINGS/EFMA%20ANNUAL%20MEETINGS/2015-Amsterdam/papers/EFMA2015_0500_fullpaper.pdf, preuzeto: [20. kolovoz 2023.].
[48] Thaler, R. H. (1999). Mental accounting matters. *Journal of Behavioral Decision Making*, 12 (3), str. 183─206.
[49] Than, K. Z. (2019). *Behavioral Factors on investment decision of Investors in Yangon Stock Exchange* (Master thesis). Department od Mangement Studies, MBA Programme, Yangon, Yangon University of Economics.
[50] Tseng, K.C., (2006). Behavioral finance, bounded rationality, neuro-finance, and traditional finance. *Investment Management and Financial Innovations*, 3(4), str.7–18.
[51] Tversky, A., & Kahneman, D. (1981). The framing of decisions and the psychology of choice. *Science*, New Series, 211 (4481), str. 453─458.
[52] Uzar, C.; Akkaya, G. Cenk (2013). The mental and behavioral mistakes investors make. *International Journal of Business and Management Studies*, 5 (1), 120-128.
[53] Valsova, D. (2016). *Behavioral Finance and Its Practical Implications for Investment Professionals (*Master Thesis). Business Administration and International Economic Relations, Empire State College, New York, State University of New York.
[54] Vuković, M. (2022). *Strukturalno modeliranje utjecaja bihevioralnih faktora na odlučivanje i performanse investitora na financijskom tržištu* (Doktorska disertacija). Ekonomski fakultet, Split, Sveučilište u Splitu.
[55] Waruingi, K. V. (2011). *A survey of behavioural factors influencing individual investors' choices of securities at the Nairobi Securities Exchange* (Master thesis). School of Business, Faculty of Business and Management Sciences, Nairobi, University of Nairobi.
[56] Waweru, N. M.; Munyoki, E.; Uliana, E. (2008). The effects of behavioural factors in investment decision-making: a survey of institutional investors operating at the Nairobi Stock Exchange. *International Journal of Business and Emerging Markets*, 1 (1), str. 24─41.

[57] Yang, M.; Mamun, A. A.; Mohiuddin, M.; Al-Shami, S. S. A.; Zainol, N. R. (2021). Predicting stock market investment intention and behavior among Malaysian working adults using partial least squares structural equation modeling. *Mathematics*, 9 (8), 873, str. 1─16.
[58] Yasmim, F.; Ferdaous, J. (2023). Behavioral biases affecting investment decisions of capital market investors in Bangladesh: A behavioral finance approach. Investment *Management and Financial Innovations*, 20 (2), str. 149─159.
[59] Zelić, M. (2017). *Bihevioralna ekonomija i efikasnost financijskih tržišta* (Diplomski rad). Diplomski rad). Odjel za ekonomiju, Diplomski sveučilišni studij menadžmenta, Zadar, Sveučilište u Zadru.

PRILOZI

Tablica 1: Demografska i poslovna obilježja ispitanika

pitanje/izjava	ponuđeni odgovori	rezultati (%)
1. spol	žensko	58,7
	muško	41,3
2. dob	18-25	14,7
	26-35	30,7
	36-45	29,3
	46 i više	25,3
3. razina obrazovanja	osnovno obrazovanje	1,3
	srednjoškolsko obrazovanje	26,7
	stručni ili sveučilišni preddiplomski studij	26,7
	specijalistički ili sveučilišni diplomski studij	40,0
	poslijediplomski znanstveni magistarski ili doktorski studij	5,3
4. bračni status	oženjen/udana	60,0
	slobodan/a	24,0
	razveden/a	4,0
	ostalo	12,0
5. Koliko dugo ste prisutni na hrvatskom financijskom tržištu?	manje od godinu dana	14,7
	1-3 godine	20,0
	5 godina	12,0
	više od 5 godina	53,3
6. Obično sudjelujem u području djelatnosti:	I: Djelatnosti pružanja smještaja te pripreme i usluživanja hrane	10,7
	K: Financijske djelatnosti i djelatnosti osiguranja	14,7
	CA: Proizvodnja prehrambenih proizvoda, pića i duhanskih proizvoda	4,0
	H: Prijevoz i skladištenje	4,0

pitanje/izjava	ponuđeni odgovori	rezultati (%)
	G: Trgovina na veliko i malo; popravak motornih vozila i motocikala	9,3
	MA: Pravne, računovodstvene, upravljačke, arhitektonske djelatnosti i inženjerstvo te tehničko ispitivanje i analiza	17,3
	ostalo	40,0
7. Jeste li pohađali neki tečaj na hrvatskom financijskom tržištu?	da	20,0
	ne	80,0
8. Kakav ste tip investitora?	špekulativan (kratkoročni)	16,0
	dugoročni (namjena ulaganja određena je postavljenim ciljevima ulaganja u dugom roku, očekujući primjerenu zaradu)	50,7
	oboje	33,3

Izvor: izrada autorica

Tablica 2: Bihevioralni faktori ulaganja ispitanika

(pod)skupina (Cronbach alpha)		izjava	ponuđeni odgovori	%	prosjeci	
heuristike (0,8255)	**reprezentativnost (0,3477)**	9. Moja prošlost utječe na sadašnje investicijske odluke.	1: u potpunosti se ne slažem	4	3,84	3,63
			2: ne slažem se	0,0		
			3: niti se slažem niti se ne slažem	28,0		
			4: slažem se	42,7		
			5: u potpunosti se ne slažem	25,3		
		10. Koristim analizu trendova nekih reprezentativnih vrijednosnih papira kako bi donio/la odluku o investiranju u vrijednosne papire.	1: u potpunosti se ne slažem	5,3		
			2: ne slažem se	8,0		
			3: niti se slažem niti se ne slažem	33,3		
			4: slažem se	34,7		
			5: u potpunosti	18,7		

(pod)skupina (Cronbach alpha)		izjava	ponuđeni odgovori	%	prosjeci	
			se ne slažem			
		11. Izbjegavam ulagati u poduzeća s lošom poviješću.	1: u potpunosti se ne slažem	1,3		
			2: ne slažem se	2,7		
			3: niti se slažem niti se ne slažem	25,3		
			4: slažem se	22,7		
			5: u potpunosti se ne slažem	48,0		
	raspoloživost (0,6464)	12. Radije kupujem lokalne vrijednosne papire nego međunarodne jer su informacije o lokalnim vrijednosnim papirima dostupnije.	1: u potpunosti se ne slažem	6,7	3,44	
			2: ne slažem se	10,7		
			3: niti se slažem niti se ne slažem	30,7		
			4: slažem se	22,7		
			5: u potpunosti se ne slažem	29,3		
		13. Ako želim kupiti vrijednosne papire u određenom poduzeću, oslonit ću se na informacije prikupljene od kolega.	1: u potpunosti se ne slažem	10,7		
			2: ne slažem se	22,7		
			3: niti se slažem niti se ne slažem	33,3		
			4: slažem se	20,0		
			5: u potpunosti se ne slažem	13,3		
		14. Investitori preferiraju lokalna tržišta u odnosu na međunarodna jer su više upućeni u zbivanja na lokalnom tržištu.	1: u potpunosti se ne slažem	5,3		
			2: ne slažem se	8,0		
			3: niti se slažem niti se ne slažem	24,0		
			4: slažem se	36,0		
			5: u	26,7		

(pod)skupina (Cronbach alpha)		izjava	ponuđeni odgovori	%	prosjeci
			potpunosti se ne slažem		
	sidrenje i prilagodba (0,5905)	15. Pokušavam procijeniti promjene cijena vrijednosnih papira u budućnosti na temelju trenutnih cijena vrijednosnih papira.	1: u potpunosti se ne slažem	2,7	3,69
			2: ne slažem se	5,3	
			3: niti se slažem niti se ne slažem	33,3	
			4: slažem se	36,0	
			5: u potpunosti se ne slažem	22,7	
		16. Kupujem "vruće" vrijednosne papire i izbjegavam vrijednosne papire koji su u nedavnoj prošlosti imali loše rezultate.	1: u potpunosti se ne slažem	5,3	
			2: ne slažem se	20,0	
			3: niti se slažem niti se ne slažem	32,0	
			4: slažem se	26,7	
			5: u potpunosti se ne slažem	16,0	
		17. Prilikom poduzimanja sljedeće investicije oslanjam se na svoja prethodna iskustva na tržištu.	1: u potpunosti se ne slažem	0,0	
			2: ne slažem se	2,7	
			3: niti se slažem niti se ne slažem	20,0	
			4: slažem se	44,0	
			5: u potpunosti se ne slažem	33,3	
	samouvjerenost (0,6536)	18. Vjerujem da mi moje vještine i znanja o financijskom tržištu mogu pomoći da nadmašim tržište.	1: u potpunosti se ne slažem	1,3	3,86
			2: ne slažem se	5,3	
			3: niti se slažem niti se ne slažem	30,7	
			4: slažem se	34,7	

(pod)skupina (Cronbach alpha)		izjava	ponuđeni odgovori	%	prosjeci	
			5: u potpunosti se ne slažem	28,0		
		19. Uvjeren/a sam u vlastito donošenje ispravne investicijske odluke.	1: u potpunosti se ne slažem	1,3		
			2: ne slažem se	2,7		
			3: niti se slažem niti se ne slažem	24,0		
			4: slažem se	49,3		
			5: u potpunosti se ne slažem	22,7		
	izbjegavanje kajanja (zabluda kockara) (0,6658)	20. Obično mogu predvidjeti kraj dobrih ili loših tržišnih prinosa na financijskom tržištu Republike Hrvatske.	1: u potpunosti se ne slažem	4,0	3,39	
			2: ne slažem se	8,0		
			3: niti se slažem niti se ne slažem	54,7		
			4: slažem se	25,3		
			5: u potpunosti se ne slažem	8,0		
		21. Predviđam promjene cijena vrijednosnih papira u budućnosti na temelju nedavnih kretanja cijena vrijednosnih papira.	1: u potpunosti se ne slažem	2,7		
			2: ne slažem se	13,3		
			3: niti se slažem niti se ne slažem	36,0		
			4: slažem se	38,7		
			5: u potpunosti se ne slažem	9,3		
		22. U stanju sam predvidjeti dobar i loš rezultat te poduzeti optimalne investicije.	1: u potpunosti se ne slažem	1,3		
			2: ne slažem se	14,7		
			3: niti se slažem niti se ne slažem	33,3		

(pod)skupina (Cronbach alpha)		izjava	ponuđeni odgovori	%	prosjeci	
			4: slažem se	32,0		
			5: u potpunosti se ne slažem	18,7		
teorija očekivanog izbora (0,7586 bez samokontrole)	**averzija prema gubitku (0,6245)**	23. Osjećam se nervozno kada cijene vrijednosnih papira u koje ulažem snažno padnu.	1: u potpunosti se ne slažem	2,7	3,66	3,50
			2: ne slažem se	10,7		
			3: niti se slažem niti se ne slažem	25,3		
			4: slažem se	32,0		
			5: u potpunosti se ne slažem	29,3		
		24. Nakon susreta s velikim gubitkom svojih ulaganja postajem neskloniji/a riziku.	1: u potpunosti se ne slažem	6,7		
			2: ne slažem se	10,7		
			3: niti se slažem niti se ne slažem	26,7		
			4: slažem se	30,7		
			5: u potpunosti se ne slažem	25,3		
		25. Više sam zabrinut/a zbog velikog gubitka vrijednosti mojih vrijednosnih papira nego zbog propuštanja značajnog dobitka.	1: u potpunosti se ne slažem	1,3		
			2: ne slažem se	17,3		
			3: niti se slažem niti se ne slažem	25,3		
			4: slažem se	37,3		
			5: u potpunosti se ne slažem	18,7		

(pod)skupina (Cronbach alpha)		izjava	ponuđeni odgovori	%	prosjeci	
		26. Radije izbjegavam investiranje u vrijednosne papire koji su nepredvidljivi.	1: u potpunosti se ne slažem	6,7		
			2: ne slažem se	8,0		
			3: niti se slažem niti se ne slažem	20,0		
			4: slažem se	30,7		
			5: u potpunosti se ne slažem	34,7		
	averzija prema žaljenju (0,5844)	27. Izbjegavam prodaju vrijednosnih papira kojima je vrijednost pala i rado prodajem vrijednosne papire kojima je vrijednost porasla.	1: u potpunosti se ne slažem	4,0	3,50	
			2: ne slažem se	5,3		
			3: niti se slažem niti se ne slažem	37,3		
			4: slažem se	34,7		
			5: u potpunosti se ne slažem	18,7		
		28. Sklon/a sam čuvanju vrijednosnih papira koji gube vrijednost čekajući bolja vremena.	1: u potpunosti se ne slažem	5,3		
			2: ne slažem se	14,7		
			3: niti se slažem niti se ne slažem	28,0		
			4: slažem se	30,7		
			5: u potpunosti se ne slažem	21,3		
		29. Više sam uznemiren/a zbog predugog držanja vrijednosnih papira koji donose gubitke nego zbog	1: u potpunosti se ne slažem	4,0		
			2: ne slažem se	16,0		
			3: niti se slažem niti se ne slažem	33,3		

(pod)skupina (Cronbach alpha)		izjava	ponuđeni odgovori	%	prosjeci	
		prerane prodaje vrijednosnih papira koji donose dobitke.	4: slažem se	26,7		
			5: u potpunosti se ne slažem	20,0		
	mentalno računovodstvo (0,4760)	30. Sklon/a sam zasebno tretirati svaki element svog investicijskog portfelja.	1: u potpunosti se ne slažem	4,0	3,35	
			2: ne slažem se	5,3		
			3: niti se slažem niti se ne slažem	29,3		
			4: slažem se	29,3		
			5: u potpunosti se ne slažem	32,0		
		31. Zanemarujem vezu između različitih mogućnosti ulaganja.	1: u potpunosti se ne slažem	9,3		
			2: ne slažem se	20,0		
			3: niti se slažem niti se ne slažem	40,0		
			4: slažem se	26,7		
			5: u potpunosti se ne slažem	4,0		
		32. Sklon/a sam različito vrednovati zarađen novac i novac dobiven na igrama na sreću.	1: u potpunosti se ne slažem	13,3		
			2: ne slažem se	12,0		
			3: niti se slažem niti se ne slažem	24,0		
			4: slažem se	21,3		
			5: u potpunosti se ne slažem	29,3		
		33. Više sam zabrinut/a za učinak svakog vrijednosnog papira pojedinačno nego za portfelj	1: u potpunosti se ne slažem	8,0		
			2: ne slažem se	5,3		
			3: niti se slažem niti	53,3		

(pod)skupina (Cronbach alpha)		izjava	ponuđeni odgovori	%	prosjeci	
		u cjelini.	se ne slažem			
			4: slažem se	22,7		
			5: u potpunosti se ne slažem	10,7		
	emocije (0,5229) i samokontrola	34. Emocije utječu na formiranje mojih stavova prilikom investiranja.	1: u potpunosti se ne slažem	8,0	3,39	
			2: ne slažem se	24,0		
			3: niti se slažem niti se ne slažem	37,3		
			4: slažem se	21,3		
			5: u potpunosti se ne slažem	9,3		
		35. Emocionalnu inteligenciju smatram važnom karakteristikom investitora.	1: u potpunosti se ne slažem	2,7		
			2: ne slažem se	10,7		
			3: niti se slažem niti se ne slažem	25,3		
			4: slažem se	29,3		
			5: u potpunosti se ne slažem	32,0		
		36. Pažljivo promatram svoje investicije i imam visoku razinu kontrole nad investicijskim odlukama.	1: u potpunosti se ne slažem	5,3	3,89	
			2: ne slažem se	2,7		
			3: niti se slažem niti se ne slažem	20,0		
			4: slažem se	41,3		
			5: u potpunosti se ne slažem	30,7		
	uokvirivanje	37. Zamislite situaciju da se pojavila smrtonosna bolest koja će odnijeti oko 600	1.opcija: bit će spašeno 200 ljudi	32,0		
			2.opcija: postoji 1/3 vjerojatnosti	68,0		

(pod)skupina (Cronbach alpha)		izjava	ponuđeni odgovori	%	prosjeci	
		života i odaberite opciju koju preferirate:	da će svih 600 ljudi biti spašeno i 2/3 vjerojatnosti da nitko neće biti spašen			
		38. Zamislite situaciju da se pojavila smrtonosna bolest koja će odnijeti oko 600 života i odaberite opciju koju preferirate:	1.opcija: stradat će 400 ljudi	30,7		
			2.opcija: postoji 1/3 vjerojatnosti da nitko neće stradati i 2/3 vjerojatnosti da će svih 600 ljudi stradati	69,3		
efekt krda (0,8075)		39. Obično brzo reagiram na promjene odluka drugih investitora i pratim njihove reakcije na tržištu vrijednosnih papira.	1: u potpunosti se ne slažem	6,7	3,10	
			2: ne slažem se	10,7		
			3: niti se slažem niti se ne slažem	45,3		
			4: slažem se	25,3		
			5: u potpunosti se ne slažem	12,0		
		40. Odluke drugih investitora o odabiru vrsta vrijednosnih papira utječu na moje investicijske odluke.	1: u potpunosti se ne slažem	6,7		
			2: ne slažem se	17,3		
			3: niti se slažem niti se ne slažem	45,3		
			4: slažem se	21,3		
			5: u potpunosti se ne slažem	9,3		
		41. Odluke drugih investitora o	1: u potpunosti se ne slažem	12,0		

(pod)skupina (Cronbach alpha)		izjava	ponuđeni odgovori	%	prosjeci	
		obujmu investiranja u vrijednosne papire utječu na moje investicijske odluke.	2: ne slažem se	18,7		
			3: niti se slažem niti se ne slažem	41,3		
			4: slažem se	18,7		
			5: u potpunosti se ne slažem	9,3		
tržišni faktori (0,6059)	**promjene cijena**	42. Pažljivo razmatram promjene cijena vrijednosnih papira u koje namjeravam investirati.	1: u potpunosti se ne slažem	1,3	4,11	4,06
			2: ne slažem se	0,0		
			3: niti se slažem niti se ne slažem	24,0		
			4: slažem se	36,0		
			5: u potpunosti se ne slažem	38,7		
	tržišne informacije	43. Informacije o tržištu važne su za moje investiranje u vrijednosne papire.	1: u potpunosti se ne slažem	2,7	4,17	
			2: ne slažem se	5,3		
			3: niti se slažem niti se ne slažem	13,3		
			4: slažem se	29,3		
			5: u potpunosti se ne slažem	49,3		
	prethodni trendovi na tržištu	44. Za svoje buduće investicije uzimam u obzir prošla kretanja vrijednosnih papira.	1: u potpunosti se ne slažem	2,7	3,89	
			2: ne slažem se	8,0		
			3: niti se slažem niti se ne slažem	20,0		
			4: slažem se	36,0		
			5: u potpunosti	33,3		

(pod)skupina (Cronbach alpha)		izjava	ponuđeni odgovori	%	prosjeci	
			se ne slažem			

Izvor: izrada autorica

Tablica 3: Uspješnost ulaganja ispitanika

obilježje (Cronbach alpha)	izjava	ponuđeni odgovori	%	prosjeci	
uspješnost ulaganja (0,7849)	45. Moja investicija pokazuje bolje rezultate od očekivanih.	1: u potpunosti se ne slažem	1,3	3,77	3,78
		2: ne slažem se	4,0		
		3: niti se slažem niti se ne slažem	37,3		
		4: slažem se	30,7		
		5: u potpunosti se ne slažem	26,7		
	46. Moje investiranje u vrijednosne papire utjecalo je na povećanje mog novčanog toka u posljednjih 5 godina.	1: u potpunosti se ne slažem	4,0	3,85	
		2: ne slažem se	1,3		
		3: niti se slažem niti se ne slažem	22,7		
		4: slažem se	36,0		
		5: u potpunosti se ne slažem	36,0		
	47. Moja stopa prinosa jednaka je ili viša od prosječne stope prinosa na tržištu.	1: u potpunosti se ne slažem	1,3		
		2: ne slažem se	8,0		
		3: niti se slažem niti se ne slažem	30,7		
		4: slažem se	37,3		
		5: u potpunosti se ne slažem	22,7		
	48. Moje investiranje u vrijednosne	1: u potpunosti se ne slažem	4,0	3,51	

obilježje (Cronbach alpha)	izjava	ponuđeni odgovori	%	prosjeci	
	papire ima visok stupanj sigurnosti.	2: ne slažem se	13,3		
		3: niti se slažem niti se ne slažem	32,0		
		4: slažem se	34,7		
		5: u potpunosti se ne slažem	16,0		
	49. Moje investiranje u vrijednosne papire ima manji rizik u usporedbi s tržištem općenito.	1: u potpunosti se ne slažem	2,7		
		2: ne slažem se	6,7		
		3: niti se slažem niti se ne slažem	38,7		
		4: slažem se	34,7		
		5: u potpunosti se ne slažem	17,3		
	50. Osjećam zadovoljstvo zbog svojih prošlogodišnjih investicijskih odluka.	1: u potpunosti se ne slažem	0,0	3,99	
		2: ne slažem se	4,0		
		3: niti se slažem niti se ne slažem	26,7		
		4: slažem se	32,0		
		5: u potpunosti se ne slažem	37,3		
	51. Zadovoljan/a sam svojim investicijskim odlukama u prošloj godini (uključujući prodaju, kupnju, odabir vrsta i obujma vrijednosnih papira).	1: u potpunosti se ne slažem	1,3		
		2: ne slažem se	5,3		
		3: niti se slažem niti se ne slažem	21,3		
		4: slažem se	40,0		
		5: u potpunosti se ne slažem	32,0		

Izvor: izrada autorica

Original scientific paper / Izvorni znanstveni rad

CUSTOMER ATTITUDES TOWARDS E-COMMERCE: CASE OF BOSNIA AND HERZEGOVINA

Professor ALMIR PEŠTEK, PhD
University of Sarajevo
School of Economics and Business
Trg oslobođenja - Alija Izetbegović 1, 71000 Sarajevo, Bosnia & Hercegovina
Phone: + 387 33 275 958
almir.pestek@efsa.unsa.ba

Teaching Assistant NADIJA HADŽIJAMAKOVIĆ, MA
University of Sarajevo
School of Economics and Business
Trg oslobođenja - Alija Izetbegović 1, 71000 Sarajevo, Bosnia & Hercegovina
Phone: +387 33 253 758
nadija.hadzijamakovic@efsa.unsa.ba

ABSTRACT

With the rise of globalisation and development of information technology, e-commerce, as an alternative buying and selling space to offline stores, gained on its importance. The e-commerce prevalence affected the way business is done by organisations, but also the consumer behaviours and their perceived value of retail space. E-commerce has been on the rise in most industries, especially followed by the recent Covid-19 pandemic. The rising trend of digital shopping behaviour in terms of the increase in online payment methods, number of mobile transactions etc. has been also evident. The on-going growth of e-commerce on a global level may be argued as evidence of people's acceptance of e-commerce. Nevertheless, some studies have found significant differences in the level of acceptance between the developed and developing countries, since the latter fall behind in terms of the digital transformation. Various theories of e-commerce acceptance have been formulated in literature to appoint to factors that drive the e-commerce acceptance. Furthermore, the user's trust in terms of the online security, variety of products available online, the competitiveness of prices or the time saved compared to offline stores have shown to be some of the general factors influencing the e-commerce acceptance both from buyers' and sellers' point of view.

This paper presents the findings of research conducted in cooperation with the E-Commerce Association Bosnia and Herzegovina in 2023 on a sample of 1,317 respondents who made purchases online. The findings of the research confirm some of the findings carried out in countries around the world, but there are also certain specificities that are reflected in the preference for the way of making purchases, the method of payment, the method of delivery, the selection of sellers, etc.

KEYWORDS: e-commerce, e-commerce acceptance, Bosnia and Herzegovina

1. INTRODUCTION

1.1. E-COMMERCE DEVELOPMENT

In the past 20 years, e-commerce developed rapidly into alternative marketplace to offline stores, mainly as a result of the continuous growth of the Internet and information technology [Haryanti and Subriadi, 2020; Bai and Li, 2022]. As the technology and connectivity became more accessible to individuals and businesses during the early 1990s, and the World Wide Web was created, the e-commerce activities expended among businesses, individuals, and industries [Chu et al., 2007]. Nevertheless, not until the early 2000's did the e-commerce develop to its full potential, with significant improvements in its instruments and technology which solved the prior issues preventing it from achieving the worldwide popularity it has today [Yoo and Yang, 2018]. The e-commerce prevalence transformed the way business is done by organisations, but also the consumer behaviours and their perceived value of retail space [Jain at al., 2021; Liu at al., 2022]. In the broader context, the recent rate of the technological change is so significant that the e-commerce has also created shifts in the world economy, influencing different areas of industry [Jain and Arya, 2021]. Gregory at al. [2017] argue that the e-commerce, as one of the biggest technological developments in the last two decades has revolutionised the businesses on a global scale bringing in numerous benefits, such as: easier access to new markets, more efficient supply chains, expanded customer base, better customer services, lower costs, and increased profits. E-commerce has been on the rise in most industries, especially followed by the recent Covid-19 pandemic, which produced a notable number of first-time online shoppers across the world which are expected to continue developing their new shopping habits [Beckers at al, 2021; Statista, 2023]. The rising trend of digital shopping behaviour in terms of the increase in online payment methods, number of mobile transactions etc. has been also evident. In 2021, the worldwide retail e-commerce sales were worth approximately 5.2 trillion U.S. dollars, while in 2022 they grew up to 5.7 trillion U.S. dollars [Statista, 2023]. According to the Eurostat data, the online shopping trend continues to grow in the European Union as well, with a twenty percent increase in the number of e-buyers from 2012 until 2022 [Eurostat, 2023]. Furthermore, Europe seems to be the area with the most rapid growth when it comes to cross-border e-commerce markets [Cheba at al., 2021; Reis and Machado, 2020].

Several drivers that may have facilitated the e-commerce development are discussed in literature. Cheba at al. (2021) argue that the information technology infrastructure, both in terms of the mobile and internet access impacted the development of e-commerce greatly, especially its use in the cities. Additionally, other external influences shaped the e-commerce development, among which the following: improved e-commerce infrastructure for the export markets, improved payment gateway systems, increased demand for e-commerce, improved transportation systems, improved government policies, improved analytics tools, expansion of social media, and the enhanced users' trust in the e-commerce market [Cheba at al., 2021; Gajda, 2020; Gregory at al., 2017; Jain at al. 2021; Sfenrianto at al., 2019]. Some authors argue that the gross domestic product also has a notable impact on the e-commerce market development [Cheba at al., 2021; Li at al., 2018]. In this context, it is important to mention social commerce, which developed together with the rapid expansion of social media, enhancing the users' trust and satisfaction with e-commerce. Prior to making buying decisions, users tend to actively rely on social commerce, due to numerous benefits social commerce offers for them, including: enhanced information search, possibility to read and write reviews, engage, save time while e-shopping, improved understanding of their needs from the seller's point of view etc. [Attar et al., 2020; Lin et al., 2019]. The advancements in mobile technology have

also significantly affected the online shopping behaviour and users' habits [Li at al., 2020; Cristofaro, 2019]. Wagner, Schramm – Klein and Steinmann (2020) argue that the trend of multichannel online shopping, including computers, smartphones, tablets, and smart TV's is affecting the online retailing in a way that it's becoming more versatile, complex and demanding in terms of the understanding of users' needs.

The on-going growth of e-commerce on a global level may be argued as evidence of people's acceptance of e-commerce [Haryanti & Subriadi, 2020]. Nevertheless, there are still several factors that can be argued as barriers to the expansion of e-commerce market, especially in the developing countries. However, these vary among individual markets. These factors include the following: lack of legislation and regulation related to e-commerce, insufficient support of financial institutions for the e-commerce infrastructure, lack of private and public sector collaboration, as well as the consumers' reluctancy to switch from traditional to online markets [Cheba et al., 2021; Hamed at al, 2008; Jain at al., 2021]. Yang at al. [2008] argue that one of the key barriers to e-commerce acceptance in past has been the lack of users' trust. Various theories of e-commerce adoption and acceptance have been formulated in literature to appoint to factors that drive the e-commerce acceptance. Hernandez at al. [2008] argue that the underlying motivations for the first-time shoppers and experienced shoppers vary based on the level of their experience. Some earlier studies suggest that buyers turn to e-commerce in order to save time and money [Punj, 2012; Haryanti & Subriadi, 2020]. However, as the prevalence of e-commerce expended, other numerous factors influencing users' acceptance of e-commerce have been discussed by researchers, such as: enhanced flexibility in shopping, access to information about products and sellers, ease of access to complementary goods and suppliers, transparency related to users' experiences and reviews, enhanced online security, competitive prices etc. [Jain at al., 2021; Haryanti and Subriadi, 2020; Hernandez at al., 2008]. Furthermore, demographic variables such as: age, language, occupation, household size, origin of birth, marital status etc. have also shown to be influencing the variances in users' e-commerce behaviour [Nasseri & Elliot, 2011].

The aim and intention of this research was to determine the needs, habits, and attitudes of e-commerce users in Bosnia and Herzegovina. The need to conduct this research is reflected in the lack of official data on the development of e-commerce in Bosnia and Herzegovina, as well as limited number of studies that can provide a deeper insight into the needs and expectations of customers in Bosnia and Herzegovina.

1.2. E-COMMERCE DEVELOPMENT IN BOSNIA AND HERZEGOVINA

Even though the ongoing growth of e-commerce in recent years is evident, the literature shows that there are differences between developed and developing countries [Cheba at al., 2021; Činjarević et al., 2021]. Compared to the research on e-commerce size and trends in the European Union and other developed countries, the research, and relevant statistical data for BiH is scarce [Jaganjac, Obhodaš and Jerković, 2020]. Nevertheless, according to UNCTAD B2C E-commerce Index 2020, Bosnia and Herzegovina has been placed amongst the top ten countries in transition when it comes to e-commerce acceptance [UNCTAD, 2020]. Based on the data provided by Statista [2022], Bosnia and Herzegovina takes only a small portion of the global e-commerce trade, with a predicted e-commerce revenue of $424.6 million by the end of 2023 and annual growth rate of 10.75 percent [Statista, 2022]. Furthermore, as indicated in the European E-commerce Report 2022, although the Western Europe has a significant precedence compared to the rest of the continent when it comes to e-commerce turnover, in

2021, Eastern Europe, with Bosnia and Herzegovina included showed higher growth in B2C e-commerce markets [Amsterdam University of Applied Sciences, 2022].

Bosnia and Herzegovina (hereinafter: BiH) is a country situated in Southeast Europe, e.g. the west part of the Balkan Peninsula, and based on the consensus from 2013 counts 3.531.159 citizens, and 1.155.736 households [Agency for Statistics of Bosnia and Herzegovina, 2023]. According to the UNDP [2023], the process of digital transformation of BiH is in progress, but its full potential still has not been reached. Today, many successful domestic e-commerce websites operate in BiH, including Olx.ba, Ekupi.ba and others [Jaganjac, Obhodaš & Jerković, 2020]. International e-commerce websites such as Ebay.com, Aliexpress.com are also available for BiH customers, while the e-commerce pioneer, Amazon.com still has not opened its doors to BiH [Ebay, 2023; Aliexpress, 2023; Amazon, 2023). Even though many international e-commerce websites are available for BiH, the research shows that the majority of BiH citizens prefer to buy from online domestic sellers [Amsterdam University of Applied Sciences, 2022; Mastercard, 2022]. The data provided in the European E-commerce Report 2022 indicates that up to 70 percent of BiH online shoppers buy from national sellers [Amsterdam University of Applied Sciences, 2022]. The research conducted by the company Mastercard confirms this pattern, while it also indicates that social commerce should not be neglected when it comes to BiH e-commerce users, since 15 percent of Mastercard users in BiH use social networks such as Facebook or Instagram for online shopping [Mastercard, 2022].

According to the research conducted by Peštek, Resić and Nožica [2011], 45 percent of research respondents in 2011 engaged in online transactions, mostly related to online sales and purchases, or e-banking. The factors such as simplicity or timesaving were mainly stated in favour of online shopping. On the contrary, 55 percent of the study respondents did not engage in online transactions due to concerns related to payment security, data privacy, website interface, lack of personal contact with seller, uncertainty related to the inability to check the product's characteristics prior to delivery, or poor access to information. Similar results were found by Selimović and Peštek [2014] in their study on consumer behaviour in online group buying in BiH. The authors argue that only a small portion of Internet users engaged in online group buying and online buying in general, mainly due to concerns related to trust in terms of money and product safety. Other reasons included a small number of Internet users in general, and complications in the payment process, since many credit/debit cards weren't authorised for online purchases. As Peštek, Resić and Nožica [2011] argue, it seems that trust was a mayor issue for online shoppers in BiH a decade ago, and in fact was an eliminating factor when it came to online transactions.

Nevertheless, based on the data from the European E-commerce Report 2022, by 2021, the Internet usage rate grew to 79 percent, while the number of e-shoppers increased to 40 percent of the BiH population [Amsterdam University of Applied Sciences, 2022]. According to the latest data, provided by the Agency for Statistics of Bosnia and Herzegovina, the Internet connections in BiH through the fixed network counted to 876.845 in the first quarter of 2023, which is an increase of more than 8 percent compared to the first quarter of 2022 [Agency for Statistics of Bosnia and Herzegovina, 2023]. In the report published by company Mastercard in 2022, the data shows that up to 40 percent of Mastercard users perform transactions at least once a week, while 23 percent of users carry out transactions for the purpose of online shopping [Mastercard, 2023]. In addition, according to the data provided in the European E-commerce Report 2022, in 2021, 52 percent of online shoppers in BiH made at least one to two purchases, 34 percent three to five purchases, while 14 percent six and more [Amsterdam University of Applied Sciences, 2022]. Based on the evident changes in the behaviour of BiH online users in

a range of 9 years, we may argue that the online shoppers in BiH have not just gained more confidence in online payment services, but also tend to engage in online shopping more frequently than before.

Another interesting data provided by the Agency for Statistics of Bosnia and Herzegovina is that the number of mobile phone users in the first quarter of 2023 was 3.589.802, which is in comparison to the number of citizens registered in the consensus from 2013 higher by 1.6% [Agency for Statistics of Bosnia and Herzegovina, 2023]. Moreover, combined with the report from 2021 conducted by the company Visa, stating that up to 26 percent of BiH citizens carry out payments using their mobile phones, we can see the growing pattern not just in the number of Internet users, but also in the number of active mobile users, additionally indicating the increase in the e-commerce trend in BiH as well [Visa, 2021].

Jaganjac, Obhodaš & Jerković (2020) argue that there is no precise data on the e-commerce trade in BiH, and that it is only possible to find the aggregate data on trade in BiH. Nonetheless, based on of the data for five most popular e-commerce platforms in BiH for the period 2015-2018, the authors argue that these companies achieved a 45 percent growth in sales revenue in 2018 compared to 2015, and that at the level of e-commerce industry, BiH achieved strong growth in the aforementioned period. Although the rate of e-commerce growth in BiH is much smaller compared to global level, it is stable, and it will continue growing in the future. During the Covid-19 pandemic, Olx.ba, one of the most visited BiH domestic e-commerce platforms, published an internal analysis report which, compared to 2020, indicates a 36 percent increase in the number of listed items for sale in 2021, as well as the 89 percent increase in the number of deliveries, which shows a growing e-commerce trend during this period [Olx, 2021].

2. METHODOLOGY

The research was conducted in December 2023 in cooperation with the E-commerce Association in Bosnia and Herzegovina.

The survey was developed by the author based on relevant studies, and previously conducted research. The survey was distributed online, and 1.317 valid answers have been collected, through respondents who had experience with online shopping.

The sample is dominated by female respondents (81.8%), which also represents one of the limitations of the research. About 58.3% of respondents are aged 26-35 (30.2%) and 36-45 (28.1%), and 18.5% of respondents are aged 18-25. Approximately 6.9% of respondents are over 55 years old. Furthermore, 65.7% of respondents live in a marriage or partnership, 52.8% of respondents have university education, and 61.5% of respondents are employed.

3. RESEARCH FINDINGS

Some of the important research findings are presented below.

The research showed that 60.7% of respondents have antivirus software installed, while 48.3% of respondents have at least one subscription to video and audio streaming services. Furthermore, 78.3% of them use the Internet or mobile banking, and 69.6% of respondents have

at least one credit or debit card that they use to pay online. Also, 21.4% of respondents have a separate bank account or card that they use exclusively for online payments.

It is interesting that approximately 28.8% of respondents had inconveniences during online shopping, 13.6% during online payment and 31.2% during delivery of ordered goods. About 7.1% had a problem with stolen or misused personal data.

Online shopping is mostly done via mobile phone (78.1%), laptop or desktop computer (20.7%) or tablet (1.2%).

When talking about the place of shopping, these are the findings:

- Websites in BiH (63.6%),
- Websites abroad (19.7%),
- Social media in BiH (15.1%) and,
- Social media abroad (1.6%).

It is also important to note that social commerce has fairly high representation in total online purchases.

As many as 35.2% of the respondents have not made purchases abroad so far. About 22.7% of respondents who bought online from abroad bought in countries of the region (Croatia, Serbia, Montenegro, Albania, and North Macedonia), 21.3% in EU countries, 10.7% in Asian countries, 4.3% in North American countries, 3.7% in other European countries, 1.4% in Central and South American countries, 0.5% in Australia, and 0.1% in Africa.

About 49.6% of respondents do not use online payment systems at all, while about 32.2% use PayPal, 8.8% Google Pay, 2.7% Apple Pay, 2.5% Payoneer and 1.4% Ali Pay and Amazon Pay. Other services include Stipe, Venmo and Square.

Table 1 shows the products that are most often bought online. There is a difference between men and women, where men mostly buy clothes (11.2%), consumer electronics (9.6%), computer equipment (8.1%), shoes (8.0%) and household items (7 .8%), and women clothing (19.1%), footwear (10.7%), household items (10.4%), and cosmetics and body care products (7.4%).

Table 1. Products and services purchased online, N=1.317

Products and services purchased online	**%**
Clothes	17.5
Footwear	10.1
Household items	9.9
Cosmetics and body care	6.4
Baby equipment	4.9
Books	4.6
Jewellery	4.5
Consumer electronics	4.3
Sports and fitness equipment	3.7
Tickets	3.7
Toys	3.5
Computer equipment	3.5
Travels	3.4

Food and drink	2.8
Watches	2.7
Products and services related to health and wellness	2.7
Furniture and decor	2.6
Digital and media services and subscriptions	2.3
Machines and tools	2.3
Medicines	2.1
Software	1.1
Music	0.6
Movies	0.6
Other	0.1
Hobby equipment	0.0
Total	100.0

Source: Authors

The preferred delivery method for online purchases in Bosnia and Herzegovina is delivery to the address via express mail (79.9%), regular mail (12.1%), home delivery by the manufacturer/seller (6.3%), and collection in the store or warehouse of the manufacturer/seller (1.7%). Delivery from abroad is done through express mail (68.4%) and regular mail (31.4%).

The preferred payment method is cash upon the delivery (69.7%), card payment (23.6%), services such as PayPal (4.8%), bank payment (1.2%) and money transfer such as Western Union (0.7%).

In Table 2 the factors for making a purchase decision are presented. It is evident that the dominant reasons are a positive experience with the manufacturer/seller in a traditional/offline store (21.2%), recommendations from friends and family (19.8%) and recommendations, positive ratings, or reviews from other customers (18.6%).

Table 2. Factors for making a purchase decision, N=1.317

Factors for making a purchase decision	**%**
Positive experience with manufacturer/retailer in traditional/offline store	21.2
Recommendations from friends and family	19.8
Recommendations, positive ratings, or reviews from other customers	18.6
Information from the website of the manufacturer/trader	9.9
Information from manufacturer/retailer profiles on social media	7.0
E-mail or newsletters to which I am subscribed	2.5
Searches on web browsers (Google, Bing, Yahoo, etc.)	5.8
Advertisements on social media	4.1
Use of search engines/price aggregators	2.3
Internet and social media forums and groups	7.1
Google ads on websites, media portals, etc	1.6
Total	100.0

Source: Authors

Table 3 shows the attitudes of the customers, which were rated from 1 (absolutely disagree) to 5 (absolutely agree). It is evident that the findings are consistent with the findings from the previous table.

Table 3. Customer Attitudes About Online Shopping, N=1.317

Statement	N	Mean	Median	Mod	Std.dev.
I prefer manufacturers/retailers who have positive ratings and comments from other customers	1285	4.10	5.00	5	1.174
I prefer platforms/manufacturers/retailers that provide the option to return/exchange products	1290	4.08	5.00	5	1.188
I prefer platforms/manufacturers/retailers that provide product warranties	1285	4.07	5.00	5	1.199
I prefer platforms/manufacturers/retailers that I have bought from before	1279	4.07	5.00	5	1.191
I prefer manufacturers/merchants who have safety certificates	1285	3.90	4.00	5	1.229
I prefer offers in which the price of delivery is included in the price of the goods	1280	3.79	4.00	5	1.289
I prefer platforms/manufacturers/retailers that provide the possibility of tracking the delivery (tracking code)	1277	3.77	4.00	5	1.254
Before making a purchase from a certain manufacturer/retailer, I always do additional research on their reliability and history of operation/performance	1284	3.75	4.00	5	1.275
When shopping online, the delivery price is particularly important to me	1284	3.75	4.00	5	1.270
I am ready to wait longer for delivery if the price of the product is favourable	1281	3.75	4.00	5	1.311
I worry about my online privacy	1277	3.74	4.00	5	1.346
I prefer platforms/manufacturers/retailers that provide customer support (call centre, e-mail, chat, etc.)	1281	3.74	4.00	5	1.296
When shopping online, I always compare several alternative offers/products	1284	3.72	4.00	5	1.263
When shopping online, I always compare several alternative suppliers	1280	3.71	4.00	5	1.285
I believe that I have enough knowledge on how to safely use the Internet	1279	3.69	4.00	5	1.246
I don't like sharing my information online	1286	3.62	4.00	5	1.359
When shopping online, I prefer manufacturers/retailers from BiH because that way I avoid customs procedures	1280	3.62	4.00	5	1.335
I prefer to buy products online from reputable/known retailers	1275	3.61	4.00	5	1.340
I worry about the possible theft of personal data when I make an online payment	1285	3.60	4.00	5	1.363
I prefer manufacturers/merchants who have lower prices than other providers	1281	3.56	4.00	5	1.326
I worry about possible identity theft when I make an online payment	1283	3.55	4.00	5	1.379
Delivery time is especially important to me when shopping online	1279	3.54	4.00	5	1.259
I prefer manufacturers/retailers that offer the possibility of joining loyalty programs	1277	3.53	4.00	5	1.294
I prefer to buy products from reputable/well known manufacturers online	1283	3.48	4.00	5	1.339
I am afraid that the product I ordered will be different from what was promised	1280	3.45	3.00	5	1.303
I avoid fewer known manufacturers/sellers when shopping online	1282	3.37	3.00	5	1.394
I prefer to gather information about the product in the store and do the shopping online	1283	3.32	3.00	5	1.430
I don't like to type in data during online payments	1275	3.30	3.00	5	1.387
I prefer to gather information about the product online and do the shopping in a traditional store	1279	3.11	3.00	3	1.361
I prefer traditional shopping over online shopping	1278	3.00	3.00	3	1.367
If I see an interesting online offer, I will buy it immediately	1280	2.72	3.00	3	1.375

I am bothered by the additional checks with a token after entering the card (3D secure)	1277	2.70	3.00	1	1.408
I am not familiar with the methods of using the cards for online payments	1273	2.13	1.00	1	1.392

Source: Authors

Table 4 shows the success factors of the web platform for electronic commerce, which were rated from 1 (absolutely disagree) to 5 (absolutely agree). It is evident that the most important thing for a customer is to be delivered what was described and within the promised time.

Table 4. Web platform success factors, N=1.317

Statement	**Mean**	**Median**	**Mod**	**Std.dev**
I received exactly what was described	4.37	5.00	5	1.026
The product was delivered when promised	4.36	5.00	5	1.019
The site provides enough information about the product	4.32	5.00	5	1.027
The site has an easy and secure payment system	4.31	5.00	5	1.040
I can find what interests me on the site	4.31	5.00	5	1.006
The site has a good reputation	4.28	5.00	5	1.057
The site provides an easy search option	4.28	5.00	5	1.039
The site provides up-to-date product information	4.27	5.00	5	1.056
The site provides product information that is easy to understand	4.26	5.00	5	1.069
The site processes the order quickly	4.26	5.00	5	1.053
The site has good shipping rates	4.26	5.00	5	1.063
The site provides relevant product information	4.25	5.00	5	1.071
The site only asks me for the necessary information to complete the transaction	4.22	5.00	5	1.114
The page loads quickly	4.21	5.00	5	1.063
The site clearly states how my information will be used	4.20	5.00	5	1.112
The site provides consistent product information	4.19	5.00	5	1.073
The privacy policy is clearly stated	4.19	5.00	5	1.106
The site also provides customer support	4.19	5.00	5	1.077
The site has detailed security information	4.18	5.00	5	1.108
The site has more favourable prices than the traditional store	4.16	5.00	5	1.129
The site is easy to navigate	4.15	5.00	5	1.099
The site has security certificates	4.15	5.00	5	1.120
The products are well packed	4.15	5.00	5	1.087
The site has a wide scope/range of products	4.10	5.00	5	1.112
The site supports the provision of recommendations and reviews	4.05	4.00	5	1.127
The site is pleasantly designed	4.03	4.00	5	1.119
The site also has additional offers/promotions	3.99	4.00	5	1.160
The site is mobile-friendly	3.98	4.00	5	1.187
The site has the possibility to compare products/prices	3.91	4.00	5	1.184
The site provides identity confirmation through a one-time password via SMS	3.90	4.00	5	1.216
The site provides identity verification through a one-time password via push message or PIN	3.85	4.00	5	1.236
The site has a simple and short domain name	3.75	4.00	5	1.276
The site provides identity verification through a one-time password through the mToken/mbanking application	3.74	4.00	5	1.271

4. CONCLUSION

The results presented in this paper confirm some of the major findings in the literature. It is evident that the customers from BiH are becoming more and more accepting of the Internet technologies and e-commerce, which is supported by the finding that 78.3% of the research respondents use the Internet or mobile banking, and up to 69.6% of respondents have at least one credit or debit card dedicated for online shopping. In addition, the influence of mobile technologies on e-commerce is confirmed in the case of BiH e-customers as well, since the findings show that up to 78.1% of respondents used mobile phones for online shopping. The trend of social commerce has been also confirmed with a 16.7% share assigned to social media when it comes to the place of shopping of the research respondents. Nevertheless, the lack of trust still remains an issue for BiH e-customers in certain aspects, especially when it comes to online payments. In fact, 21.4% of respondents have a separate bank account or card that they use exclusively for online payments, indicating a slight distrust and concern for money safety. Additionally, up to 49.6% of respondents do not use online payment systems at all, while as many as 69.7% of respondents prefer cash upon the delivery as a payment method. Furthermore, the findings also confirmed that BiH e-customers show a modest aversion towards engaging in e-shopping with e-sellers from abroad, since as many as 35.2% of the respondents have not made purchases abroad so far. Finally, it is evident that customers value the trustworthiness of the seller and the positive experience in terms of the promised vs. delivered value amongst all. The research limitation is reflected in a fact that the sample was dominated by female respondents (81.8%), so it would be interesting to include more responses from male respondents in the future studies.

REFERENCES

[1] Agency for Statistics of Bosnia and Herzegovina (2023). Elektronske komunikacije, prvi kvartal 2023 [first release], https://shorturl.at/azX24, downloaded: [August 21st, 2023]

[2] Amsterdam University of Applied Sciences (2022). European E-commerce Report 2022, https://shorturl.at/kKM56, downloaded: [August 20nd, 2023]

[3] Attar, R. W; Shanmugam, M; Hajli, N. (2021). Investigating the antecedents of e-commerce satisfaction in social commerce context. British Food Journal, 123(3), 849-868

[4] Bai, Y; Li, H. (2022). Mapping the evolution of e-commerce research through co-word analysis: 2001–2020. Electronic Commerce Research and Applications, 55, 101190

[5] Beckers, J; Weekx, S., Beutels, P; Verhetsel, A. (2021). COVID-19 and retail: The catalyst for e-commerce in Belgium?. Journal of Retailing and Consumer Services, 62, 102645

[6] Cheba, K; Kiba-Janiak, M; Baraniecka, A; Kołakowski, T. (2021). Impact of external factors on e-commerce market in cities and its implications on environment. Sustainable Cities and Society, 72, 103032

[7] Chu, S. C; Leung, L. C.; Van Hui, Y.; Cheung, W. (2007). Evolution of e-commerce Web sites: A conceptual framework and a longitudinal study. Information & Management, 44(2), 154-164

[8] Činjarević, M; Pijalović, V; Peštek, A; Lazović-Pita, L; Karić, L. (2021). Heading out SMEs to the e-commerce highway: Drivers of the e-commerce perceived usefulness among SMEs in Bosnia and Herzegovina. Management: Journal of Contemporary Management Issues, 26(1), 3-20

[9] Cristofaro, M. (2020). E-business evolution: an analysis of mobile applications' business models. Technology Analysis & Strategic Management, 32(1), 88-103

[10] Eurostat (2023). E-commerce continues to grow in the EU, https://shorturl.at/dvT05, downloaded: [July 12th, 2023]
[11] Gajda, K. (2020). Factors shaping inter-organizational trust in e-commerce based on literature review. Management – Poland, 24(1), 23–38
[12] Gregory, G. D; Ngo, L. V; Karavdic, M. (2019). Developing e-commerce marketing capabilities and efficiencies for enhanced performance in business-to-business export ventures. Industrial Marketing Management, 78, 146-157
[13] Hamed, A; Ball, D; Berger, H; Cleary, P. (2008). The three-quarter moon: A new model for E-commerce adoption. Innovation and Knowledge Management in Business Globalization: Theory & Practice, 1(2), 1342–1350
[14] Haryanti, T; Subriadi, A. P. (2020). Factors and theories for E-commerce adoption: A literature review. International Journal of Electronic Commerce Studies, 11(2), pp 87-106
[15] Hernandez, B; Jimenez, J; José Martín, M., 2009. Adoption vs acceptance of e-commerce: two different decisions. European Journal of Marketing, 43(9/10), pp.1232-1245
[16] Jaganjac, J., Obhodaš, I., & Jerković, D. (2020). Forecast of E-Commerce Growth in Bosnia and Hercegovina. EMC Review-Economy and Market Communication Review, 19(1), 151-166
[17] Jain, V., Malviya, B., & Arya, S. (2021). An overview of electronic commerce (e-Commerce). Journal of Contemporary Issues in Business and Government, 27(3), 665-670
[18] Li, Z; Luan, D; Zhang, Y; Guo, P. (2018). The evaluation of e-commerce efficiency in China using DEA-tobit model: Evidence from Taobao data. WHICEB, Proceedings, 73
[19] Lin, X; Wang, X; Hajli, N. (2019). Building e-commerce satisfaction and boosting sales: The role of social commerce trust and its antecedents. International Journal of Electronic Commerce, 23(3), 328-363
[20] Liu, X; Tong, D; Huang, J; Zheng, W; Kong, M., & Zhou, G. (2022). What matters in the e-commerce era? Modelling and mapping shop rents in Guangzhou, China. Land Use Policy, 123, 106430
[21] Mastercard (2022). Masterindex Bosna i Hercegovina istraživanje, https://shorturl.at/dlGLV, downloaded [August 22nd, 2023]
[22] Naseri, M. B; Elliott, G. (2011). Role of demographics, social connectedness and prior internet experience in adoption of online shopping: Applications for direct marketing. Journal of Targeting, Measurement and Analysis for Marketing, 19, 69-84
[23] Peštek, A; Resić, E; Nožica, M. (2011). Model of trust in e-transactions. Economic research-Ekonomska istraživanja, 24(3), 131-146
[24] Punj, G. (2012). Income effects on relative importance of two online purchase goals: Saving time versus saving money? Journal of Business Research, 65(5), 634–640
[25] Reis, A. D; Machado, M. A. (2020). E-commerce in emerging markets: Internationalization factors of brazilian footwear in south america. Revista Gestao & Tecnologia-Journal of Management and Technology, 20(1), 165–189
[26] Selimović, L; Peštek, A. (2014). Analyzing consumer behavior in online group buying in Bosnia and Herzegovina. UTMS Journal of Economics, 5(1), 41-52
[27] Sfenrianto, S; Oktavianni, J. M. H; Putra, H. P; Khoerintus. (2019). User perspective on external value creation factors in Indonesia e-Commerce. International Journal of Advanced Computer Science and Applications, 10(7)
[28] Statista (2022). E-commerce – Bosnia and Herzegovina, https://shorturl.at/pqz01, downloaded: [August 22nd, 2023]
[29] Statista (2023). Digital Shopping Behaviour, https://rb.gy/1ir58 ,downloaded: [July 11th, 2023]

[30] UNCTAD (2020). The Unctad B2c E-commerce Index 2020: Spotlight on Latin America and the Caribbean. United nations (UNCTAD), https://shorturl.at/GIJQ0, downloaded: [August 22nd, 2023]
[31] UNDP (2023). Digital transformation in the public sector in BiH, https://shorturl.at/mEU19, downloaded: [August 15th, 2023]
[32] Visa (2021). Visa research: Almost a quarter of consumers in Serbia use mobile payments with big potential for digital wallets growth at the market, https://shorturl.at/zHXY1, downloaded: [August 21st, 2023]
[33] Wagner, G; Schramm-Klein, H; Steinmann, S. (2020). Online retailing across e-channels and e-channel touchpoints: Empirical studies of consumer behavior in the multichannel e-commerce environment. Journal of Business Research, 107, 256-270
[34] Yang, Q; Huang, L; Xu, Y. (2008). Role of trust transfer in e-commerce acceptance. Tsinghua Science and Technology, 13(3), 279-286
[35] Yoo, B; Jang, M. (2019). A bibliographic survey of business models, service relationships, and technology in electronic commerce. Electronic Commerce Research and Applications, 33, 100818

Original scientific paper / Izvorni znanstveni rad

GEN Z AND TRAVEL STORYTELLING: I WANT TO SHARE MY STORY TOO*

IVONA MIKULANDRA VOLIĆ
University of Zadar
Department of Economics
Splitska 1, 23000 Zadar, Croatia
imvolic@unizd.hr

JOSIPA PERKOV
University of Zadar
Department of Economics
Splitska 1, 23000 Zadar, Croatia
jperkov@unizd.hr

IVONA VRDOLJAK RAGUŽ
University of Dubrovnik
Department of Economics and Business
Lapadska obala 7, 20000 Dubrovnik, Croatia
ivona.vrdoljak@unidu.hr

ABSTRACT

This study explores the significance of storytelling in the travel process for Generation Z (Gen Z), with a specific focus on their engagement with social media platforms. Gen Z members are very active on social networks when it comes to travel. Starting from the assumption that travel has become a marker of status among Gen Z, the objective of this research is to investigate the influence of other people's travel stories on the share of travel stories by Gen Z on social networks. To achieve this, an online survey was conducted among 93 students at the University of Zadar, the University of Dubrovnik, and the University of Pula. The research hypotheses were tested using SEM-PLS analysis. The study draws on the social comparison theory and generation theory as its theoretical foundation. The findings of this study indicate that seeking self-esteem and other people's travel stories significantly affects the sharing of travel stories on social media among Gen Z students at the selected universities. This research contributes to the existing knowledge on the power of storytelling in tourism for Gen Z and highlights the need for further investigation into the motivational aspects of storytelling.

KEYWORDS: travel storytelling, Gen Z, social media, social comparison, seeking self-esteem, tourism

* The paper was financed by the funds of the institutional scientific project "Youth and the Experience Economy - New Paradigm and Innovative Business Models" (MLADCI) of the University of Zadar.

1. INTRODUCTION

A necessary prerequisite for the effective marketing of a tourist destination is an understanding of their target groups and their activities on social media. Across various social networks, content concerning tourist destinations, products, and experiences is disseminated not only by Destination Management Organizations (DMOs), hotel operators, and travel companies but also by individual users who actively engage in generating content. Travel storytelling on social media is an important part of destination marketing strategies and DMOs are facing the challenge that destination marketing and destination brand design are less influenced by the marketing strategies and stories created by the DMOs and increasingly depend on people's shared tourism experiences and storytelling in social networks [Lund et al., 2018]. There are two types of tourists regarding sharing of travel experiences on social media, posters and lurkers. Posters are engaged with social media platforms and they share their travel experiences [Oliveira et al., 2020]. Motivations and reasons for using social media as a medium for storytelling gain the attention of researchers [Yilmaz, 2016; Manap and Adzharudin, 2013; Anggarawati and Saputra, 2023] and their findings vary from helping potential tourists avoid bad experiences when traveling [Anggarawati and Saputra, 2023] to social media and tourism addiction [Suhud et al., 2023]. Generation Z (gen Z), a cohort of individuals born in 1995 up to 2010, emerges as an important market segment for many destinations. Their behavior before, during, and after travel is increasingly attracting the attention of tourism managers and researchers as well. Research into the motivations driving Gen Z tourists to share their travel experiences on social media platforms remains relatively limited.

In this paper travel storytelling was researched from the tourist's perspective – travel stories as a form of user generated content (UGC) and in the lenses of Gen Z tourists' motivation to post their travel stories on social media. The objectives of this study were: (1) to assess the impact of other people's travel stories on Gen Z tourists' intentions to share their own travel experiences on social media after their trips, (2) to examine the relationships between variables related to self-presentation and social comparison in the context of Gen Z tourists sharing travel stories on social media and (3) to explore how the motivation stemming from expected memorable tourism experiences influences Gen Z tourists in sharing their travel experiences on social media following their journeys. The purpose of this study was to determine whether Gen Z individuals are motivated to share their travel stories by the narratives of others and to ascertain whether their reasons for sharing extend beyond mere documentation. These motivations may include a desire to share unique and memorable experiences, enhance their perceived expertise, or bolster their self-esteem in response to the appraisals of their reference group.

2. THEORETICAL FOUNDATIONS

According to the assumptions of the generation theory, the Gen Z cohort is a group of individuals who share the same experience worthy of mention that contributes to the formation of similar behavior and value creation [Kamenidou et al., 2021;122]. Gen Z adolescents actively engage in self-presentation and social comparison on social media [Mann and Blumberg, 2022]. Theoretical frameworks related to self-presentation and social comparison are often used together when explaining behavior on social networks, especially among young people [e.g. Vogel and Rose 2016; Rawat et al., 2023; Colmekcioglu et al., 2023].

2.1. GEN Z CHARACTERISTICS AND SELF-PRESENTATION ON SOCIAL MEDIA

Kamenidou et al. (2021) identified several characteristics of Gen Z members, including their role as internet content creators and their strong desire for unique and memorable experiences, often associated with travel. Styvén and Foster (2018) found a positive correlation between the importance of feeling unique in travel experiences and the likelihood of sharing those experiences on social media. On the contrary, Anggarawati and Saputra (2023) found that the need for uniqueness of young travelers does not significant effect on the propensity to share electronic Word of Mouth (e-WOM). For young tourists, act of sharing travel experiences on social media becomes a key part of experiencing travel moments [Magasic, 2016]. Self-congruity in a tourism context „involves a process of matching (some dimension of) a tourist's self-concept with the destination image" [Sirgy et al., 2018]. Cifci (2022) suggests that tourism experience self-congruity influences post-trip behavior and the perceived social value of the experience directly and positively influences the use of digital social networks [Luna-Cortés, 2017]. Cifci (2022) confirmed a positive relationship between self-congruity and the memorable tourism experience and Rasoolimanesh et al. (2021) confirmed the strong and positive effects of memorable tourism experience (MTE) on eWOM. Therefore, we hypothesize that:

H1. Expected memorable tourism experience travel motivation is positively related to the intention to share travel stories on social media after travel.

H2. Self-image congruity with a travel experience is positively related to the intention to share travel stories on social media after travel.

2.2. GEN Z SOCIAL COMPARISON AND TRAVEL STORIES

The social comparison theory [Festinger, 1954], as applied to our study, suggests that individuals have an inherent need to evaluate themselves by comparing their experiences with those of others, particularly on social media platforms [Liu et al., 2019; Taylor, 2020; Hajli et al. 2018; Siegel and Wang, 2019]. The social comparison appears in two possible directions – downward and upward social comparison. Travel experience sharing on social media is a process of upward social comparison [Liu et al., 2019] - when the comparison target is believed to be superior to oneself.

Social media has a very strong impact on the self-esteem of individuals and majority of the people end up making upward and downward comparisons with others [Jan et al., 2017]. Self-esteem can be used as a predictor of tourists' behavior. Tourists with high self-esteem have few barriers to using social media while traveling and sharing content because they hope to get praise, likes, and positive comments from their followers and acquaintances (Suhud et al., 2023). Individuals with low self-esteem may not differ from individuals with higher self-esteem in their propensity to share their travel stories on social media. Barry et al. (2017;56) offers a rationale for these results in the fact that social media posting provides "an alternative to in-person self-disclosure in a safe, controlled setting". Due to the above reason, this research does not check how self-esteem affects the sharing of travel stories on social networks, but rather how seeking self-esteem as a travel motivation affects the sharing of travel stories on social networks among Gen Z.

Reflected appraisal of self refers to how individuals' self-views are influenced by their perceptions of how others view them [Wallace and Tice, 2012]. According to Jaret et al. (2005) reflected appraisals (perceptions of the reactions of others) and self-esteem are negatively related people who perceive that others relate to them in terms of roles and statuses tend to

score lower on self-esteem. Anggarawati and Saputra (2023) found that reflected self-appraisal of young travellers positively and significantly affects the propensity to share e-WOM. Therefore, the following hypotheses are proposed:
H3. Watching stories of friends and peers on social media before travel are positively related to the intention to share travel stories on social media after travel.
H4. Seeking self-esteem travel motivation is positively related to the intention to share travel stories on social media after travel.
H5. Sensitivity to the appraisals of the reference group is positively related to the intention to share travel stories on social media after travel.

3. METHODS

3.1. SAMPLING AND DATA COLLECTION

This research is based on the hypothesis that college students are a valuable demographic [Pan and Satchabut, 2022], representing a significant portion of the oldest Gen Z members within the 18-24 age group [The Annie E. Casey Foundation's KIDS COUNT Data Center, 2023]. Studying college students provides a valuable opportunity to gain insights into the travel stories sharing intentions of this influential demographic and develop targeted strategies within the travel industry. E-mail invitations to participate in a survey were sent to all students enrolled in the University of Zadar, the University of Dubrovnik, and the University of Pula in 2022/2023. The research was conducted through an online survey during the period from March 15th to March 31st, 2023. and a total of 102 responses were collected. Nine cases were excluded from the analysis: seven respondents were above the age of 30; one case was eliminated due to responses falling more than 0.5 standard deviations from the mean on items measured using a five-point Likert Scale, and one case was removed due to two missing answers. To address missing data, five missing answers on five different questions, each from different respondents, were replaced with the respective mean values for those questions. Consequently, the data analysis involved 93 cases, which were retained for further examination.

3.2. SURVEY INSTRUMENT

Data was gathered using a self-administered online questionnaire in Croatian. The survey consisted of carefully selected questions aimed at assessing the constructs outlined in the proposed conceptual model, with the measurement instruments adapted from relevant literature sources. After pilot research and panel discussion, a selection of questions was made and some of the questions were modified according to the suggestions of the respondents. Descriptive statistics of respondents' characteristics: female (76%), male (24%); age (19-21: 54%; 22-24: 37%; 25-29: 9%); study (undergraduate: 90%, graduate: 10%); non-single child: 89%. Almost all respondents' have intentions to travel soon (mean 4.7; median 5; standard deviation 0.6). Source of information in selecting a tourist destination were Internet (62%) and social media (22%).

The survey was adapted and modified from previous studies (Table 1). The intention to post a travel story was measured by the item "I travel to put my pictures on social media" Agreeing with this statement, the respondents characterized themselves as posters. Based on the result of a panel discussion respondents suggested replacing the word story with a picture (e.g. modified question "I travel to put my story on social media" with "I travel to put my pictures on social media" because they associate the term story in Croatian with the post in text form and term

story in English exclusively with a posting on Instagram and the expression “posting the picture on social media" comprises photos, videos, and stories posting and the majority of their travel posts on social media are in form of stories. A five-point Likert scale was applied to measurement items (1 = strongly disagree to 5 = strongly agree).

Table 1. Measurement items

Construct	Measurement items (VIF)	Source
Seeking self-esteem travel motivation (SE)	I travel to tell others about my travel experiences. ** I travel to gain the respect of others. (1.989) I travel to gain a sense of achievement or accomplishment. (2.786) I travel to gain self-esteem. * I travel to feel privileged or important. (1.793) I travel to enjoy a place where others value and appreciate me. (2.483)	Otoo et al. (2020)
Expected memorable experience tourism motivation (MTE)	I travel to destinations where I expect memorable experiences. (1.000)	modified from Kim et al. (2012)
Other people travel stories on social media (SBT)	I travel after seeing pictures of my friends on social media (1.000)	Yousaf et al. (2023)
Reflected appraisal of self (RAS)	I sometimes talk about my experiences in tourist destinations, just to let others know the kind of person I am. (1.629) After experiencing experience in tourist destinations similar to those of my friend's experience, I want to let them know. (1.663) I am often concerned with the impression friends may form of me because of the experiences in tourist destinations I experienced. (1.571)	Kim et al. (2015)
Self-image congruity (SIC)	Experiences in destinations that I visit reflect who I am. (1.000) I think experiences in destinations I visit help me become the type of person I want to be. * I think experiences in destinations I visit help me become the type of person I want to be. *	modified from Kim et al. (2015)
Intention to post travel stories on social media (SAT)	I travel to put my travel pictures on social media. (1.000)	Yousaf et al. (2023)

*Excluded from analysis because Hair et al. (2019) recommends that particles with an external loading coefficient of less than 0.708 should be removed from further analysis

** Excluded from analysis because respondents of a focus group during discussion pointed out that statements „I travel to tell others about my travel experiences.” and “I travel to put my travel pictures on social media” have the same meaning to them.

Source: Authors

3.3. RESULT OF HYPOTHESIS TESTING

Partial least squares structural equation modeling (PLS-SEM) is a variance-based SEM approach that focuses on explaining the variance of endogenous latent constructs [Hair et al., 2021]. In information systems research, PLS-SEM is widely used for prediction and theory development with complex models and formative constructs [Chong et al., 2017]. Recent assessment of IS studies indicates PLS-SEM is appropriately applied and overall the field

demonstrates maturity in using the method, though some best practices such as complete reporting procedures should continue to improve [Chong et al., 2017].

Table 2. Construct reliability and validity

	Cronbach's alpha	Composite reliability (rho_a)	Composite reliability (rho_c)	Average variance extracted (AVE)
Reflected Appraisal of Self	0.781	0.816	0.870	0.691
Self Esteem	0.836	0.841	0.890	0.671

Source: Authors

The measurement model was assessed by examining the indicator loadings, internal consistency reliability, convergent validity, and discriminant validity [Chong et al., 2017]. The indicator loadings were all significant and above the 0.7 threshold (Cronsbach's alpha in Table 2). Composite reliability (rho_a in Table 2) for each constructs exceeded 0.8, demonstrating good internal consistency reliability [Hair et al., 2021]. The average variance extracted (AVE in Table 2) for each construct was greater than 0.5, satisfying convergent validity criteria. Finally, the HTMT (see Table 3) between all construct pairs was below 0.85, providing evidence of discriminant validity [Henseler et al., 2015]. Overall, the measurement model assessment supported the reliability and validity of the construct measures.

Table 3. Discriminant validity – Heterotrait-Monotrait Ratio (HTMT)

	Expected memorable experience	Reflected appraisal of self	Self-esteem	Self-image congruity	Story after travel	Story before travel
Expected memorable experience						
Reflected appraisal of self	0.060					
Self-esteem	0.282	0.720				
Self-image congruity	0.131	0.506	0.339			
Story after travel	0.96	0.430	0.454	0.275		
Story before travel	0.120	0.339	0.285	0.227	0.474	

Source: Authors

The structural model was assessed by examining the VIF, R^2 values, f^2 effect sizes, and bootstrapping results. The VIF values (in Table 1) for all constructs were below 3, indicating no issues with multicollinearity [Hair et al., 2021]. The R^2 value for the endogenous construct *Story before travel* was 0.336 which exceeds the 0.25 threshold for acceptable predictive power [Chong et al., 2017]. The f^2 effect size (in Table 4) was 0.174, signifying a medium to large effect. A bootstrapping procedure with 1000 resamples was used to evaluate the significance of the path coefficients [Hair et al., 2021]. Path coefficients (in Table 5) for *Self-esteem* and *Story before travel* had t-values greater than 1.96 and p-values below 0.05, supporting their statistical significance. The bootstrapping results provided evidence for the hypothesized relationships in the structural model.

Table 4. f-square

	Expected memorable experiences	Reflected Appraisal of Self	Self Esteem	Self-Image Congruity	Story after travel	Story before travel
Story after travel	0.001	0.013	0.054	0.005		0.174

Source: Authors

Table 5. Path coefficients – Mean, STDEV, T values, p values bootstrapping (1000)

	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (O/STDEV)	P values
Expected memorable experiences -> Story after travel	-0.020	-0.016	0.084	0.244	
Reflected Appraisal of Self -> Story after travel	0.122	0.131	0.112	1.083	0.279
Self Esteem ->Story after travel	0.240	0.245	0.245	1.997	0.048
Self-image Congruity -> Story after travel	0.064	0.056	0.103	0.619	0.536
Story before travel -> Story after travel	0.362	0358	0.080	4.516	0.000

Source: Authors

The structural model results (The path coefficients and significance of the conceptual model are visually depicted in Figure 1 provided support for two of the five hypothesized relationships. Both hypotheses concerning Gen Z self-presentation and intention to share travel experiences in social media after travel (H1 and H2) are rejected. It is not confirmed that neither travel motivation nor self-image congruity with a travel experience is positively related to the propensity to share travel experiences on social media after travel. From three hypotheses concerning Gen Z social comparison and travel stories, two were supported (H3 and H4), and one was rejected (H5).

Figure 1. SEM-PLS results

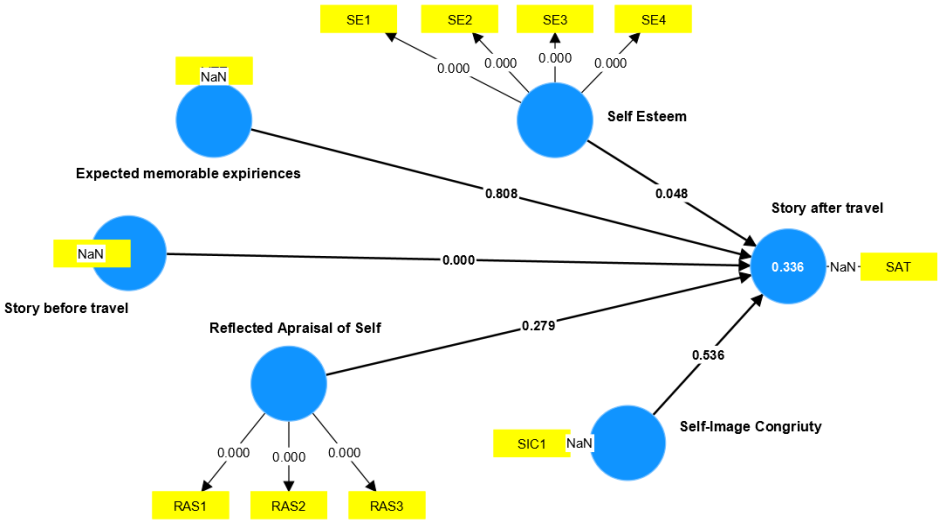

Source: Authors

4. CONCLUSION AND IMPLICATIONS

The findings of this study reveal several intriguing insights into the travel behavior of Generation Z (Gen Z) members and their motivations for sharing travel stories on social media. Firstly, it is evident that Gen Z individuals are influenced by the travel stories of others when posting their own stories, aligning with the characteristics of their destination choice process. Despite the importance Gen Z places on unique tourism experiences, this study did not find a positive relationship between expected memorable tourism experience travel motivation and the intention to share travel stories on social media. This suggests that their motives for travel story sharing may differ from the pursuit of uniqueness [Oliveira et al., 2020] or bragging about their travels [Liu et al., 2023]. However, seeking self-esteem travel motivation emerged as a significant factor positively influencing Gen Z's intention to share travel stories on social media, indicating a strong connection between travel experiences, social status, and self-esteem [Siegel and Wang, 2019]. While this study did not find strong evidence that Gen Z shares travel stories for social appraisal from their reference group [Crocker and Park, 2003], it aligns with previous research suggesting that they may not primarily seek likes or validation from others [Verma et al., 2023]. It's worth noting that this study did not assess the opinion-leadership level of respondents, which could yield different results, as indicated by Kim et al. (2015).

In the broader context of consumer socialization generational cohort research, this study contributes empirical insights into the post-travel behavior of Gen Z, shedding light on the specific ways in which they engage with social networks to share their travel experiences. It underscores the transformative role of social networks in shaping how Gen Z members interact with tourist experiences. Sharing these experiences on social media has become an integral part of Gen Z's travel behavior, with personal goal achievement being a significant motivator, overshadowing the choice of destination.

REFERENCES

[1] Anggarawati, S; Saputra, F. E. (2023). If I don’t share my unforgettable journey, I'll lose it! Young travellers’ propensity to share e-WOM on social media. *Frontiers in Business and Economics*, *2*(1), pp. 1-9, 2023.

[2] Annie E. Casey Foundation (updated on February 14, 2023, and originally posted October 29, 2020, by the Annie E. Casey foundation). Statistics Snapshot: Generation Z and Education [available at: https://www.aecf.org/blog/generation-z-and-education, access June 30, 2023]

[3] Barry, C. T; Doucette, H; Loflin, D. C; Rivera-Hudson, N; Herrington, L. L. (2017). “Let me take a selfie”: Associations between self-photography, narcissism, and self-esteem. *Psychology of popular media culture*, *6*(1), pp. 48-60, 2017.

[4] Chong, A. Y. L; Hollingsworth, C. L; Randolph, A. B. (2017). An updated and expanded assessment of PLS-SEM in information systems research. *Industrial Management and Data Systems*, 117(3), pp. 442-458, 2017.

[5] Cifci, I. (2022). Testing self-congruity theory in Bektashi faith destinations: The roles of memorable tourism experience and destination attachment. *Journal of Vacation Marketing*, *28*(1), pp. 3-19, 2022.

[6] Colmekcioglu, N; Dedeoglu, B. B; Okumus, F. (2023). Resolving the complexity in Gen Z's envy occurrence: A cross-cultural perspective. *Psychology and Marketing*, *40*(1), pp. 48-72, 2023.

[7] Crocker, J; Park, L. E. (2003). *Seeking self-esteem: Construction, maintenance, and protection of self-worth*. In M. R. Leary and J. P. Tangney (Eds.), Handbook of self and identity (pp. 291–313). The Guilford Press.
[8] Festinger, L. (1954). A theory of social comparison processes. *Human relations*, *7*(2), pp. 117-140, 1954.
[9] Hair Jr, J; Hair Jr, J. F; Hult, G. T. M; Ringle, C. M; Sarstedt, M. (2021). *A primer on partial least squares structural equation modeling* (PLS-SEM). Sage publications.
[10] Hajli, N; Wang, Y; Tajvidi, M. (2018). Travel envy on social networking sites. *Annals of Tourism Research*, 73, pp. 184-189, 2018.
[11] Henseler, J; Ringle, C. M; Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43(1), pp. 115-135, 2015.
[12] Jan, M; Soomro, S; Ahmad, N. (2017). Impact of social media on self-esteem. *European Scientific Journal*, 13(23), pp. 329-341, 2017.
[13] Jaret, C; Reitzes, D. C; Shapkina, N. (2005). Reflected appraisals and self-esteem. *Sociological Perspectives*, *48*(3), pp. 403-419, 2005.
[14] Kamenidou, I; Vassilikopoulou, A; Priporas, C. V. (2021). *New sheriff in town? Discovering Generation Z as tourists*. In Generation Z Marketing and Management in Tourism and Hospitality: The Future of the Industry (pp. 121-140). Cham: Springer International Publishing.
[15] Kim, D; Jang, S; Adler, H. (2015). What drives café customers to spread eWOM? Examining self-relevant value, quality value, and opinion leadership. *International Journal of Contemporary Hospitality Management*, 27(2), pp. 261-282, 2012.
[16] Kim, J. H; Ritchie, J. B; McCormick, B. (2012). Development of a Scale to Measure Memorable Tourism Experiences. *Journal of Travel Research*, 51(1), pp. 12-25, 2012.
[17] Liu, H; Li, X; Cohen, S. (2023). Is travel bragging in the eye of the beholder? Bragger and audience perspectives. *International Journal of Tourism Research*, 25(5), pp. 475-490, 2023.
[18] Liu, H; Wu, L; Li, X. (2019). Social media envy: How experience sharing on social networking sites drives millennials' aspirational tourism consumption. *Journal of travel research*, *58*(3), pp. 355-369, 2019.
[19] Luna-Cortés, G. (2017). The influence of tourism experience self-congruity on the use of virtual social networks. *European Journal of Tourism Research*, 16, pp. 154-176, 2017.
[20] Lund, N. F; Cohen, S. A; Scarles, C. (2018). The power of social media storytelling in destination branding. *Journal of destination marketing and management*, 8, pp. 271-280, 2018.
[21] Magasic, M. (2016). The 'selfie gaze'and 'social media pilgrimage': Two frames for conceptualising the experience of social media using tourists. *In Information and Communication Technologies in Tourism 2016: Proceedings of the International Conference,* Bilbao, Spain, February 2-5, 2016 (pp. 173-182). Springer International Publishing.
[22] Manap, K. A; Adzharudin, N. A. (2013). The role of user generated content (UGC) in social media for tourism sector. *In The 2013 WEI international academic conference proceedings* Vol. 7, No. 1, pp. 52-58).
[23] Mann, R. B; Blumberg, F. (2022). Adolescents and social media: The effects of frequency of use, self-presentation, social comparison, and self esteem on possible self imagery. *Acta Psychologica*, *228*, article 103629, 2022.
[24] Oliveira, T; Araujo, B; Tam, C. (2020). Why do people share their travel experiences on social media?. *Tourism Management*, *78*, article 104041, 2020.

[25] Otoo, F. E; Kim, S; Choi, Y. (2020). Understanding senior tourists' preferences and characteristics based on their overseas travel motivation clusters. *Journal of Travel and Tourism Marketing*, *37*(2), pp, 246-257, 2020.
[26] Pan, S; Satchabut, T. (2022). Predicting Generation Z's Travel Intention through Structural Equation Modeling. *GMSARN International Journal 16*, pp. 232-239, 2022.
[27] Rasoolimanesh, S. M; Seyfi, S; Hall, C. M; Hatamifar, P. (2021). Understanding memorable tourism experiences and behavioural intentions of heritage tourists. *Journal of Destination Marketing and Management*, 21, article 100621, 2021.
[28] Rawat, B; Fones, L. S. E; Soh, M. Y. W; Chan, V. X. (2023). *How do I measure up (or down)? Exploring the link between social comparison and online self-presentation on LinkedIn*. Final Year Project (FYP), Nanyang Technological University, Singapore
[29] Siegel, L. A; Wang, D. (2019). Keeping up with the joneses: emergence of travel as a form of social comparison among millennials. *Journal of Travel and Tourism Marketing*, *36*(2), pp. 159-175, 2019.
[30] Sirgy, M. J; Lee, D. J; Yu, G. B; Prebensen, N; Uysal, M; Chen, J. (2018). *Self-congruity theory in travel and tourism: Another Update*. Creating experience value in tourism, 2, pp. 57-69, 2018.
[31] Styvén, M. E; Foster, T. (2018). Who am I if you can't see me? The "self" of young travellers as driver of eWOM in social media. *Journal of Tourism Futures*, *4*(1), pp. 80-92, 2018.
[32] Suhud, U; Allan, M; Prihandono, D; Monoarfa, T. (2023). We are cyborgs: The role of narcissism and self-esteem to become social media and tourism addicts. *International Journal of Data and Network Science*, *7*(1), pp. 73-82, 2023.
[33] Taylor, D. G. (2020). Putting the "self" in selfies: how narcissism, envy and self-promotion motivate sharing of travel photos through social media. *Journal of Travel and Tourism Marketing*, *37*(1), pp. 64-77, 2020.
[34] Verma, K; Dhodi, R. K; Dhodi, R. (2023). *The Influence of Instagram on Generation Z Travel Motivation and Destination Choice Making to the Actual Travelling.* In Technology and Social Transformations in Hospitality, Tourism and Gastronomy: South Asia Perspectives (pp. 54-63). GB: CABI.
[35] Vogel, E. A; Rose, J. P. (2016). Self-reflection and interpersonal connection: Making the most of self-presentation on social media. *Translational Issues in Psychological Science*, *2*(3), 294-302, 2016.
[36] Wallace, H. M; Tice, D. M. (2012). *Reflected appraisal through a 21st-century looking glass*. In M. R. Leary and J. P. Tangney (Eds.), Handbook of self and identity (pp. 124–140). The Guilford Press.
[37] Yilmaz, B. S. (2016). Storytelling on Social Media: The Motives for Telling the Tourist Experience to the Connected Others. *Acta Universitatis Danubius. Communicatio,* 10(2), pp. 136-149, 2016.
[38] Yousaf, A; Mishra, A; Amin, I. (2023). Autonomous/controlled travel motivations and their effect on travel intentions of Indian Millennials: a mixed method approach. *Tourism Recreation Research*, 48(2), pp. 286-304, 2023.

Original scientific paper / Izvorni znanstveni rad

THE ROLE OF IMMERSIVE TECHNOLOGY ON INTENTION TO VISIT A TOURIST DESTINATION: GEN Z AND SPATIAL PRESENCE EXPECTATIONS*

JOSIPA PERKOV
University of Zadar
Department of Economics
Splitska 1, 23000 Zadar, Croatia
jperkov@unizd.hr

IVONA MIKULANDRA VOLIĆ
University of Zadar
Department of Economics
Splitska 1, 23000 Zadar, Croatia
imvolic@unizd.hr

ANTE PANJKOTA
University of Zadar
Department of Information Sciences
Ul. dr. F. Tuđmana 24i, 23000 Zadar, Croatia
apanjkot@unizd.hr

ABSTRACT

Expected immersive experiences in tourist destinations are one of the main attractors for Gen Z in the destination choice process. Immersive technologies such as virtual reality and augmented reality facilitate immersive experience creation but also have various characteristics enabling different levels of immersion. Immersive technologies enable a more significant spatial presence by boosting the different senses of being in the actual or virtual environment. Following the approach that technology initiatives in immersive experience creation should be tourist driven (Scholz & Smith, 2016), in this paper the authors examine which level of spatial presence Gen Z expects in immersive experiences in a tourist destination. This paper aims to gain a deeper understanding of the impact of the expected level of spatial presence on the intention to visit tourist destinations among Gen Z. Structural equation modelling is used to test direct and indirect relationships between intention to visit tourist destination and expected level of spatial presence, immersive tendencies, and expected enjoyment to estimate the potential benefits of different immersive technologies usages in tourist immersive experience creation for Gen Z. An online questionnaire was used to collect data from students from the University of Dubrovnik, the University of Pula, and the University of Zadar as representatives of Gen Z. The main finding of this study emphasizes that Gen Z's higher level of expected spatial presence of immersive environments in tourist destinations has a positive effect on their intention to visit a particular destination. This study fills the gap in the research on Gen Z's travel destination choice process. Also, it provides an empirical basis for a deeper understanding of the role of immersive experiences and immersive technologies in the pre-travel phase of the travel process for Gen Z. This study does not include any investigation on

an essential part of the observed phenomenon related to lack of immersive technology adoption for tourist providers due to the high costs or lack of understanding of their potential benefits for immersive experiences creation. Finally, this paper discusses practical implications and offers reflexions for further research.

KEYWORDS: immersive technology, Gen Z, spatial presence expectations, intention to visit tourist destination.

* The paper was financed by the funds of the institutional scientific project "Youth and the Experience Economy - New Paradigm and Innovative Business Models" (MLADCI) of the University of Zadar.

1. INTRODUCTION

The tourism and hospitality industry has experienced a rapid transformation with the emergence of immersive technologies [Pratisto et al., 2022], offering new avenues to engage and captivate travelers. Within this evolving landscape, Generation Z (Gen Z), born between the mid-1990s and early 2010s, is not merely entering the travel market; they are significantly shaping it. Despite their youth and relatively modest incomes, over half of American Gen Z adults are frequent travelers, embarking on three or more leisure trips within the past year [Morning Consult, 2023]. This study employed the Generational theory, which suggests that individuals born within the same timeframe tend to exhibit similar behaviors and characteristics due to shared influences from technological, economic, and political developments [Robinson and Schänzel, 2019]. The use of immersive technologies such as virtual reality (VR) and augmented reality (AR) has a significant impact on the travel industry, and Gen Z is known for their love of immersive technologies [Pratisto et al., 2022; Nguyen et al., 2023; Fan et al., 2022]. By applying this theory, this study aims to explore how immersive technologies impact the destination choices of Gen Z. Understanding the role of immersive technologies in attracting Gen Z travelers is crucial for destination management organizations (DMOs) seeking to harness these technologies effectively.

In alignment with Liberatore and Wagner (2021), this study collectively addresses VR and AR as immersive systems. It is essential to consider the risks associated with prematurely committing to specific technologies or platforms, as advocated by Scholz and Smith's (2016) research on consumer-driven approaches to immersive technology initiatives in tourism. Prior research has identified a research gap in exploring the relationship between immersive technology and behavioral outcomes in tourism [Skard et al., 2021; Kim et al., 2021].

Immersion is a critical dimension of the tourism experience and one of the key items in the experience economy concept. In the third generation of the experience economy: the role of VR in the provision of services is growing [Alexiou 2020; Hudson et al. 2019; Flavián et al. 2019]; the role of the producer/service provider is changing - the importance of the customer/recipient is growing, becoming (co)creator of their own experiences [Antón et al. 2018; Zhang et al. 2019; Sugathan and Ranjan 2019] and companies are facing the challenge of creating experiences and new attractions for young people - generations Y and Z.

According to Krešić and Prebežac (2011) tourism attractions are specific destination features which could attract visitors. The great potential of immersive technologies in creation tourist attractions is being recognized by tourism companies and DMO’s. Robinson and Schänzel

(2019) point out that less technologically enabled tourism destinations can benefit by employing contemporary principles and practices to meet the needs of the new generation of tourists who seek rich digital and gamified tourism experiences.

This paper empirically examines the influence of immersive technologies on Gen Z travelers' attraction to destinations, focusing on their immersive tendencies, anticipated enjoyment of immersive technologies in destinations, and intention to visit destinations offering immersive experiences. A survey questionnaire was administered to college students representing Gen Z. The collected data was rigorously analyzed using SEM-PLS, facilitating a comprehensive assessment of the interrelationships among the variables under investigation.

In conclusion, this study aims to deepen our understanding of the impact of immersive technologies in attracting Gen Z travelers. By exploring their immersive tendencies, anticipated enjoyment of immersive technologies, and intention to visit destinations offering immersive experiences, this research contributes to the growing body of knowledge in the field. The findings provide insights that can inform the marketing strategies of DMOs and the development efforts of destinations, enabling them to effectively engage and cater to the preferences of Gen Z travelers in the evolving landscape of immersive technologies.

2. LITERATURE REVIEW AND HYPOTHESIS DEVELOPMENT

2.1. IMMERSIVE TECHNOLOGIES AND GEN Z TRAVELERS

VR technologies are gaining popularity in tourism for enhancing customer experiences [Guttentag, 2010] and AR has been a common immersive technology used in tourism research in past ten years according to Pratisto et al. (2022). However, technical difficulties diminished its usefulness. Study by Jung et al. (2015) highlights the need to ensure proper functioning of AR apps to maximize benefits for tourists. It informs the current research by underscoring the importance of seamless integration of immersive technologies. Comprehensive and systematic overview of AR and VR features in tourism research and immersive technology applications within the tourism area can be found in Pratisto et al. (2022) since it is out of the scope of this paper.

Surge in enthusiasm for travel among Gen Z can be attributed to the increasing mainstream acceptance of travel and their exposure to travel-related inspiration through social media platforms. According to Lindsey Roeschke, a travel and hospitality analyst at Morning Consult, they are growing up in a society where travel holds a higher priority compared to previous generations. This shift underscores the importance for brands to take notice of the evolving travel preferences of this generation [Morning Consult, 2023]. Gen Z travelers display distinct motivations and behaviors compared to other generations. A survey of over 1500 youth travelers found that Gen Z placed highest importance on cost, safety, and recommendations from friends and family when selecting destinations [Garikapati et al., 2016]. The findings highlight Gen Z’s pragmatism and reliance on peer input.

2.2. INTENTION TO VISIT A TOURIST DESTINATION WITH IMMERSIVE TECHNOLOGIES

In an experimental study testing a VR tourism promotion video, Huang et al. (2016) observed that VR significantly increased interest and intentions to visit the destination when compared

to a 2D video. The immersive nature of VR effectively transported and engaged viewers, ultimately enhancing their intentions to visit. This highlights the potential of VR as a powerful tool for pre-travel marketing. Similarly, a study focusing on AR guides conducted by Chung et al. (2015) found that AR technology increased intentions among travelers to follow recommended itineraries and routes at heritage sites during their journeys. By improving information accessibility, AR enhanced intentions related to site navigation and exploration. Moreover, it is worth noting that some researchers advocate for a personalized approach to marketing tourist destinations through immersive technology, tailored to consumers' profiles, experiences, and preferences, rather than adopting a one-size-fits-all strategy [Skard et al., 2021].

In summary, these studies collectively highlight the potential of immersive technologies to positively influence intentions to visit destinations, whether in the context of pre-travel marketing, on-site navigation, or post-trip reminiscing. This reinforces the value of immersive technologies throughout the entire travel journey, contributing to the generation of tourism intentions. Furthermore, it provides essential context for understanding the potential impact of immersive technologies on the destination choices of Gen Z.

2.3. SPATIAL PRESENCE EXPECTATIONS

Weibel and Wissmath (2011) define spatial presence, also referred to as telepresence or presence, as a state of consciousness that gives the impression of being physically present in a mediated world. According to Kim et al. (2021) studying the impact of spatial presence on the enjoyment of media content in non-entertainment contexts such as VR tourism is an underexplored but necessary question. Based on discussion above, we propose the following hypothesis:
H1: *There is a significant direct positive effect of expected spatial presence experience in tourist destinations on their intention to visit a destination that offers immersive experience.*

2.4. IMMERSIVE TENDENCIES

Witmer and Singer (1998) introduced and validated the Immersive Tendencies Questionnaire (ITQ) as a tool to assess differences in individuals' propensities for experiencing a sense of presence in virtual environments. Notably, individuals with higher immersive tendencies reported greater involvement and a heightened sense of presence in VR environments. This questionnaire offers a valuable framework for gauging the immersive tendencies of Gen Z. A study utilizing the ITQ, conducted by Schuemie et al. (2005), found that participants with prior video game experience tended to score higher in immersive tendencies. These findings suggest that familiarity with technology may be linked to a greater capacity for immersion. This insight holds significant implications for technology-savvy generations like Gen Z, who, due to their extensive exposure to digital technology, may be predisposed to immersive experiences.
H2: *There is a significant direct positive effect of immersive tendencies on expected spatial presence of immersive environments in tourist destinations.*
H3: *Immersive tendencies influence expectations of spatial presence experiences, which, in turn, affect the intention to visit a destination that offers immersive experience.*

2.5. EXPECTED ENJOYMENT IN TOURIST DESTINATION

In an experimental study, Guttentag (2010) found that VR significantly increased enjoyment when compared to 2D web visualization for choosing tourism destinations. Participants

perceived the VR experience as more fun, exciting, and engaging. This highlights the potential of VR to enhance enjoyment in the travel planning process. Similarly, a study involving museum visitors by Jung et al. (2015) revealed that AR apps increased enjoyment by seamlessly combining digital interactivity with physical exhibits. However, it is worth noting that technical issues and glitches were identified as factors that could diminish the overall enjoyment of AR experiences. Thus, ensuring seamless functionality is vital for maximizing AR enjoyment. Building on this research, Li and Chen (2019) provided evidence that under certain conditions, VR may inhibit tourists' travel intentions. Nevertheless, their findings shed new light on technology-related tourism studies by highlighting the role of expected enjoyment of the destination as a significant intrinsic motivation that positively influences tourists' travel intentions. This perspective aligns with previous research conducted by Hew et al. (2018), which also recognized expected enjoyment as a key intrinsic motivation for travel intentions. These studies collectively demonstrate the potential of immersive technologies such as VR and AR to enhance enjoyment in tourism contexts by providing vivid, interactive, and novel experiences. We propose the following hypothesis:
H4: *There is a significant direct positive effect of expected enjoyment of immersive technologies in tourist destinations on intention to visit a destination that offers immersive experience.*
Research model is shown in Fig. 1.

Figure 1. Conceptual model

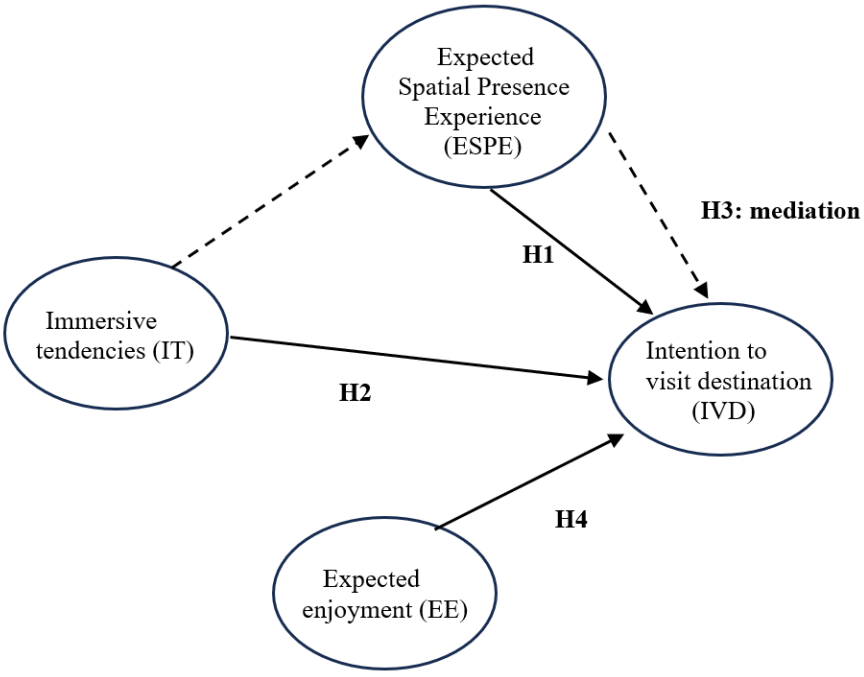

Source: Authors

3. RESEARCH METHODOLOGY

3.1. PROCEDURE AND SAMPLE

This study focuses on college students as a valuable subgroup of Gen Z travelers aged 18-29. Data from Annie E. Casey foundation (2023) shows the proportion of 18–24-year-olds in the U.S. who are college students rose from 36% to 49% between 2000-2019, revealing their

growing dominance. College students have distinctive traits like ample leisure time, autonomy in decision-making, and inclination to explore new experiences as active consumers [Pan and Satchabut, 2022]. Investigating this influential demographic offers insights into Gen Z travel intentions and helps formulate strategies targeting their preferences.

E-mail invitations to participate in a survey were sent to all active students in a University of Zadar, University of Dubrovnik and University of Pula in 2022/2023. The research was conducted through an online survey during the period from March 15th to March 31st, 2023. and a total of 102 responses were collected. Total of nine cases were removed because seven respondents were more than 30 years old, one case was removed because it had less than 0.5 standard deviation on items measured on a five-point Likert Scale, and one case was removed because it had two missing answers. Five missing answers on five different questions left by five different respondents were replaced by the mean value for that question. Finally, the data analysis included 93 cases that were retained for further examination.

3.2. MEASURES

All measures and their items are in Table 1. Respondents indicated their agreement with each item on a Likert scale of 1 (strongly disagree) to 5 (strongly agree) for every measure previously described.

Table 1. Measurement items

Construct (Cronbach's alpha; AVE) **Measurement items (VIF)**	**Source**
Immersive tendencies (α = 0.714, AVE = 0.777) *IT1 – I am so involved in doing something that I lose all track of time** *IT2 – I am so involved in a book that people have trouble getting my attention** *IT3 – I am so involved in a television program that people have trouble getting my attention. (1.444)* *IT4 – I am so involved in a video game that it is as if I am inside the game. (1.444)* *IT5 –As a spectator, I am so involved in a sporting event or competition that I react as if I was one of the players** *IT6 – I am so involved in a daydream that I am not aware of things happening around me** *IT7 – I have dreams that are so real that I feel totally disoriented when I awake**	Witmer and Singer (1998), Loureiro Krassmann et al. (2020)
Expected spatial presence experience (α = 0.926; AVE = 0.771) *ESPE1 - I would like to feel like I am there in the surrounding of immersive technology. (3.230)* *ESPE2 - I would like it seems as though I take part in the action of immersive technology. (3.807)* *ESPE3 - I would like it is as though my true location is shifted into the environment of immersive technology. (3.675)*	Hartmann et al. (2016)

ESPE4 - I would like to feel as though I am physically present in the environment of immersive technology. (3.733) *ESPE5 - I would like the objects in the immersive technology give me the feeling that I can do things with them** *ESPE6 - I would like to have the impression that I can be active in the environment of the immersive technology** *ESPE7 - I would like to feel that I can move around among the objects in the immersive technology** *ESPE8 - I would like it seems to me that I can do whatever I want in the environment of the immersive technology. (2.552)*	
Expected enjoyment (α = 0.918; AVE = 0.859) *EE1 – I would have fun using some of the immersive technology in the destination. (2.867)* *EE2 – The use of immersive technologies in the destination is interesting. (3.812)* *EE3 – I would feel comfortable using immersive technologies in the destination** *EE4 – I would feel excited about the use of immersive technologies in the destination. (3.509)*	Hew et al. (2018)
Intention to visit destination *IVD - This year I will try to visit a destination that offers an immersive experience.*	

**Excluded from analysis because Hair et al. (2019) recommends that particles with an external loading coefficient of less than 0.708 should be removed from further analysis*

Source: Authors

3.3. METHODS

Partial least squares structural equation modeling (PLS-SEM) was employed in this study to empirically examine and assess the proposed hypotheses. The rationale for utilizing this scientific method can be derived from an extensive review conducted by Hair et al. (2019) in which they argue that PLS-SEM has been widely adopted in diverse social science disciplines, including management research, as it facilitates better understanding of complex data relationships with many constructs, indicator variables and structural paths by generating strong model validity and reliability without imposing distributional assumptions on the data. Software SmartPLS 4, Ver. 4.0.9.5 was used for data analysis.

4. RESULTS

4.1. SAMPLE DESCRIPTIVE STATISTICS

Descriptive statistics of respondents' characteristics: Female (76%), Male (24%); Age (19-21: 54%; 22-24: 37%; 25-29: 9%); Study (Undergraduate: 90%, Graduate: 10%); non-single child: 89%. Almost all respondents' have intentions to travel soon (mean 4.7; median 5; standard deviation 0.6).

4.2. HYPOTHESIS TESTING

The measurement model demonstrated adequate reliability and validity for all reflective constructs. All indicator loadings exceeded 0.7 and were significant. The composite reliability values ranged from 0.714 to 0.926, exceeding the recommended 0.7 threshold [Hair et al., 2021]. The average variance extracted (AVE) ranged from 0.771 to 0.859, above the 0.5 cutoff established by Fornell and Larcker (1981). Discriminant validity was supported using the Heterotrait-monotrait (HTMT) ratio of correlation. HTMT criterion shown in Table 2, with all values below 0.85 [Henseler et al., 2015].

Table 2. HTMT

	EE	ESPE	IT	IVD
EE				
ESPE	0.766			
IT	0.460	0.678		
IVD	0.414	0.444	0.250	

Source: Authors

The hypothesis testing results (presented in Table 3) provided support for three out of four hypothesized relationships. The R^2 values were 0.311 for ESPE and 0.202 for IVD exceeding the 0.10 minimum recommended for social science research [Hair et al., 2011]. A bootstrapping analysis showed that the path coefficients from ESPE to IVD (β=0.311, $p<0.05$) and from IT to ESPE (β=0.553, $p<0.001$) were statistically significant, while relationships from EE to IVD were not significant. The indirect relationship between IT and the IVD, mediated by ESPE, was supported. Overall, the PLS-SEM results provided partial support for the hypothesized model. The SmartPLS analysis yielded a saturated model SRMR value of 0.072. As a rule of thumb, SRMR values less than 0.08 are considered favorable [Henseler et al., 2015]. The saturated model SRMR of 0.072 is below the suggested 0.08 cut-off, indicating an acceptable fit relative to the correlation matrix of the sample data.

Table 3. Hypothesis testing results

Hypothesis	**β coefficient**	***t* value**	***p* value**	**Result**
H1: ESPE -> IVD	0.311	1.843	0.033*	accepted
H2: IT -> IVD	-0.035	0.293	0.385	rejected
H3: IT -> ESPE -> IVD	0.173	1.764	0.039*	accepted
H4: EE -> IVD	0.191	1.250	0.106	rejected

* $p < 0.05$

Source: Authors

In summary, this paper has presented only the most salient results of the SEM-PLS. While the key findings have been highlighted and discussed here, the analysis generated additional detailed output that could not be covered in full within the length limits of this article. For readers interested in examining the comprehensive PLS-SEM results, please contact the authors to request the full output data. The additional model details, including extended path coefficients, R-squared values, f-squared effect sizes, prediction relevance metrics, and bootstrapping outcomes can provide further insight into the relationships between constructs

and the model's predictive capabilities. Though only abbreviated here, the full results reinforce the conclusions of this study regarding the impact of immersive technologies on attracting Generation Z travelers.

5. CONCLUSION AND IMPLICATIONS

The PLS-SEM analysis provided partial support for the hypothesized model. The findings indicate that Gen Z travelers exhibit immersive tendencies and anticipate enjoyment from engaging with immersive technologies during their travels. Notably, expectations of spatial presence were found to directly influence intentions to visit destinations offering immersive experiences. Furthermore, immersive tendencies had an indirect effect on visit intentions through heightened spatial presence expectations. However, the data did not support a direct link between anticipated enjoyment and visit intentions.

Taken together, these results reveal the nuanced and indirect role of immersive technologies in shaping Gen Z's travel decision-making, with spatial presence expectations acting as a key intermediary factor connecting their innate immersive tendencies to greater intention to visit destinations that offer immersive experience.

In summary, the findings highlight the nuanced impact of immersive technologies on Generation Z travelers. The findings from this study offer valuable insights into the attitudes and preferences of Gen Z travelers regarding immersive technologies. Results indicate that this cohort exhibits immersive tendencies, reflecting their inclination to actively engage with immersive experiences. This observation aligns with the broader characteristics of Gen Z, known for their affinity for digital technologies and interactive encounters [McKinsey & Company, 2023; Wertz, 2022]. In addition, survey responses suggest a positive expectation of enjoyment when engaging with immersive technologies in destinations, signifying the potential of these technologies to enhance the overall travel experience for Gen Z travelers. However, a notable finding is that the presence of immersive technologies is not the sole determinant in destination selection for Gen Z travelers. Factors such as value for money (47%), availability of cheap flights (45%), and safety and security (42%) have significant influence on their decision-making [TravelPerk, 2023].

This research contributes to existing knowledge by shedding light on the impact of immersive technologies in attracting Gen Z travelers. By examining their immersive tendencies, anticipated enjoyment of immersive technologies, and intention to visit destinations offering immersive experiences, this study provides insights for DMOs and tourism professionals seeking to tailor their strategies to the preferences of Gen Z travelers in the evolving landscape of immersive technologies. Thus, an effective strategy may be to promote the innovative immersive experiences as part of a holistic destination experience that aligns with Gen Z priorities.

This study has certain limitations that provide opportunities for additional research. The relatively small sample size of 93 students reduces the generalizability of the findings. Future studies should investigate a larger and more diverse sample of Gen Z travelers. Also, this research was limited to the demand perspective, examining Gen Z travelers' attitudes and preferences regarding immersive technologies. The supply perspective was not addressed, as barriers to adoption of these emerging technologies by tourism providers were not investigated. A holistic understanding requires exploring both provider and tourist viewpoints. This study

isolated the impact of immersive technologies, while actual destination experiences integrate multiple features and services. Further research could examine synergistic relationships between immersive technologies and other elements that shape the visitor experience. As consumer behaviors, enabling technologies, and destination offerings continue to evolve rapidly, ongoing investigation mapping the intersection of these phenomena will remain valuable.

In summary, this study provides useful initial insights but has limitations stemming from its narrow scope. Significant opportunities exist for future research to build on these findings through investigating broader samples, incorporating provider perspectives, examining holistic destination experiences, and continuing inquiry as the relevant technologies and markets progress.

REFERENCES

[1] Alexiou, M. V. (2020). Experience economy and co-creation in a cultural heritage festival: consumers' views. *Journal of Heritage Tourism*, 15(2), pp 200-216.

[2] Annie E. Casey Foundation (2023). Statistics Snapshot: Generation Z and Education, https://www.aecf.org/blog/generation-z-and-education, downloaded: [June, 30th 2023]

[3] Antón, C.; Camarero, C.; Garrido, M. J. (2018). Exploring the experience value of museum visitors as a co-creation process. *Current issues in Tourism*, 21(12), pp 1406-1425.

[4] Chung, N.; Han, H.; Joun, Y. (2015). Tourists' intention to visit a destination: The role of augmented reality (AR) application for a heritage site. *Computers in Human Behavior*, 50, pp 588-599.

[5] Garikapati, V. M.; Pendyala, R. M.; Morris, E. A.; Mokhtarian, P. L.; McDonald, N. (2016). Activity patterns, time use, and travel of millennials: a generation in transition? *Transport Reviews*, 36(5), pp 558-584.

[6] Guttentag, D. A. (2010). Virtual reality: Applications and implications for tourism. *Tourism management*, 31(5), pp 637-651.

[7] Fan, X.; Jiang, X.; Deng, N. (2022). Immersive technology: A meta-analysis of augmented/virtual reality applications and their impact on tourism experience. *Tourism Management*, 91, Article 104534.

[8] Flavián, C.; Ibáñez-Sánchez, S.; Orús, C. (2019). The impact of virtual, augmented and mixed reality technologies on the customer experience. *Journal of Business Research*, 100, pp 547-560.

[9] Fornell, C.; Larcker, D. F. (1981). Evaluating structural equation models with unobservable variables and measurement error. *Journal of Marketing Research*, 18(1), pp 39–50.

[10] Hair, J. F.; Ringle, C. M.; Sarstedt, M. (2011). PLS-SEM: Indeed a silver bullet. Journal of Marketing Theory and Practice, 19(2), pp 139-152.

[11] Hair, J. F.; Risher, J. J.; Sarstedt, M.; Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM, *European Business Review*, 31(1), pp 2–24.

[12] Hair Jr, J.; Hair Jr, J. F.; Hult, G. T. M.; Ringle, C. M.; Sarstedt, M. (2021). *A primer on partial least squares structural equation modeling (PLS-SEM)*. Sage publications.

[13] Hartmann, T.; Wirth, W.; Schramm, H.; Klimmt, C.; Vorderer, P.; Gysbers, A.; Böcking, S.; Ravaja, N.; Laarni, J.; Saari, T.; Gouveia, F.; Sacau, A. M. (2016). The spatial presence experience scale (SPES). *Journal of Media Psychology*. 28(1), pp 1-15.

[14] Henseler, J.; Ringle, C. M.; Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43(1), pp 115-135.
[15] Hew, J. J.; Leong, L. Y.; Tan, G. W. H.; Lee, V. H.; Ooi, K. B. (2018). Mobile social tourism shopping: A dual-stage analysis of a multi-mediation model. *Tourism Management*, 66, pp 121-139.
[16] Huang, Y. C.; Backman, S. J.; Backman, K. F.; Moore, D. (2013). Exploring user acceptance of 3D virtual worlds in travel and tourism marketing. *Tourism Management*, 36, pp 490-501.
[17] Hudson, S.; Matson-Barkat, S.; Pallamin, N.; Jegou, G. (2019). With or without you? Interaction and immersion in a virtual reality experience. *Journal of Business Research*, 100, pp 459-468.
[18] Jung, T.; Chung, N.; Leue, M. C. (2015). The determinants of recommendations to use augmented reality technologies: The case of a Korean theme park. *Tourism management*, 49, pp 75-86.
[19] Kim, J.; Shinaprayoon, T.; Ahn, S.J. (2021). Virtual tours encourage intention to travel and willingness to pay by experiencing the beauty of the place, enjoying the scenery, and capturing the image of the destination. *Journal of Current Issues & Research in Advertising*, 43, pp 90 - 105.
[20] Krešić, D.; Prebežac, D. (2011). Index of destination attractiveness as a tool for destination attractiveness assessment. Tourism: *An International Interdisciplinary Journal*, 59(4), pp 497-517.
[21] Li, T.; Chen, Y. (2019). Will virtual reality be a double-edged sword? Exploring the moderation effects of the expected enjoyment of a destination on travel intention. *Journal of Destination Marketing & Management*, 12, pp 15-26.
[22] Liberatore, M. J.; Wagner, W. P. (2021). Virtual, mixed, and augmented reality: a systematic review for immersive systems research. *Virtual Reality*, 25(3), pp 773-799.
[23] Loureiro Krassmann, A.; Melo, M.; Peixoto, B.; Pinto, D.; Bessa, M.; Bercht, M. (2020). Learning in virtual reality: Investigating the effects of immersive tendencies and sense of presence. In *Proceedings of a Virtual, Augmented and Mixed Reality. Industrial and Everyday Life Applications: 12th International Conference, VAMR 2020*, pp 270-286, Copenhagen, Denmark.
[24] McKinsey & Company (2023). What is gen Z? Generation Z collection, https://www.mckinsey.com/featred-insights/mckinsey-explainers/what-is-gen-z, downloaded: [September, 23rd 2023]
[25] Morning Consult (2023). Gen Z travel trends: Travel often, save money, and seek adventure, https://www.cnbc.com/2023/04/17/gen-z-travel-trends-travel-often-save-money-and-seek-adventure-.html, downloaded: [September, 23rd 2023]
[26] Nguyen, T. B. T.; Le, T. B. N.; Chau, N. T. (2023). How VR Technological Features Prompt Tourists' Visiting Intention: An Integrated Approach. *Sustainability*, 15(6), Article 4765.
[27] Pan, S.; Satchabut, T. (2022). Predicting Generation Z's Travel Intention through Structural Equation Modeling. *GMSARN International Journal* 16, pp 232-239.
[28] Pratisto, E. H.; Thompson, N.; Potdar, V. (2022). Immersive technologies for tourism: a systematic review. *Information Technology & Tourism*, 24(2), pp 181-219.
[29] Robinson, V. M.; Schänzel, H. A. (2019). A tourism inflex: Generation Z travel experiences. *Journal of tourism futures*, 5(2), pp 127-141.
[30] Schuemie, M. J.; Van Der Straaten, P.; Krijn, M.; Van Der Mast, C. A. (2001). Research on presence in virtual reality: A survey. *Cyberpsychology & behavior*, 4(2), pp 183-201.

[31] Scholz, J.; Smith, A. N. (2016). Augmented reality: Designing immersive experiences that maximize consumer engagement. *Business Horizons*, 59(2), pp 149-161.
[32] Skard, S.; Knudsen, E. S.; Sjåstad, H.; Thorbjørnsen, H. (2021). How virtual reality influences travel intentions: The role of mental imagery and happiness forecasting. *Tourism Management*, 87, Article 104360.
[33] Sugathan, P.; Ranjan, K. R. (2019). Co-creating the tourism experience. *Journal of Business Research*, 100, pp 207-217.
[34] TravelPerk (2023). 30+ Gen Z travel statistics and trends, https://www.travelperk.com/blog/gen-z-travel-statistics-trends/, downloaded: [September, 23rd 2023]
[35] Weibel, D.; Wissmath, B.; Mast, F. W. (2010). Immersion in mediated environments: The role of personality traits. *Cyberpsychology, Behavior, and Social Networking*, 13(3), pp 251-256.
[36] Weibel, D.; Wissmath, B. (2011). Immersion in Computer Games: The Role of Spatial Presence and Flow. *International Journal of Computer Games Technology*, 2011 (ID 282345), pp 1-14.
[37] Wertz, J. (2022). Generation Z Gravitates Towards Immersive Tech-Driven Experiences, https://www.forbes.com/sites/jiawertz/2022/11/30/generation-z-gravitates-towards-immersive-tech-driven-experiences/?sh=686244735ab6, downloaded: [September, 23rd 2023]
[38] Witmer, B. G.; Singer, M. J. (1998). Measuring presence in virtual environments: A presence questionnaire. *Presence*, 7(3), pp 225-240.
[39] Zhang, C. X.; Fong, L. H. N.; Li, S. (2019). Co-creation experience and place attachment: Festival evaluation. *International Journal of Hospitality Management*, 81, pp 193-204.

Original scientific paper / Izvorni znanstveni rad

STRATEŠKO ZNAČENJE INFLUENCERA I DESIGN THINKING U KREIRANJU INTEGRIRANOG KORISNIČKOG ISKUSTVA*

MADONNA OJUROVIĆ ČAČIĆ
Sveučilište u Zadru
Odjel za ekonomiju
Splitska 1, 23000 Zadar, Hrvatska
mojurovic@student.unizd.hr

ANTONIJA RAŽOV
Sveučilište u Zadru
Odjel za ekonomiju
Splitska 1, 23000 Zadar, Hrvatska
atrajk13@gmail.com

ALEKSANDRA KRAJNOVIĆ
Sveučilište u Zadru
Odjel za ekonomiju
Splitska 1, 23000 Zadar, Hrvatska
akrajnov@unizd.hr

SAŽETAK

U novije vrijeme influenceri su postali važan segment digitalnog marketinga, a prenošenje marketinške poruke mlađim kupcima izazovan je zadatak za voditelje marketinškog odjela. U ovom radu istražuje se pitanje strateškog značenja influencera i integriranje koncepta design thinking u digitalni marketing i kreiranje integriranog korisničkog iskustva. U radu se u fokus razmatranja postavlja stvaranje zabavne vrijednosti za kupce kroz sadržaj kojega influenceri plasiraju gradeći tako blizak i kvalitetan odnos s pratiteljima. Naglašava se značenje influencera i sponzoriranog sadržaja na Instagramu u cilju povećanja marketinške učinkovitosti. U radu se prikazuju i rezultati primarnog istraživanja. Cilj istraživanja bio je ispitivanje mišljenja i stavova potrošača o influencerima i njihovog utjecaja na kupovne odluke. Istražuje se i korelacija s konceptom design thinking kojim se kroz kreativno rješavanje problema pomaže razumjeti potrebe ljudi za koje se stvara proizvod ili usluga. Praktične implikacije rada ogledaju se u doprinosu spoznajama relevantnima za uvođenje integriranog korisničkog iskustva koje se provodi kroz mape proučavanja korisničkog iskustva, pri čemu se prate interakcije i prikupljaju podaci kako bi se izgradili dosljedni profili kupaca s ciljem da im se u konačnici pruži cjelovito kupovno iskustvo. U posljednjem dijelu rada iznosi se kritički osvrt autorica na rezultate, kao i zaključni stavovi i smjernice za daljnja istraživanja.

KLJUČNE RIJEČI: influencer, influencer marketing, design thinking, korisničko iskustvo mapa korisničkog iskustva – CJM

* Ovaj rad financiran je sredstvima institucionalnog znanstvenog projekta Sveučilišta u Zadru 'MLADCI – Mladi i ekonomija iskustva – nova paradigma i inovativni poslovni modeli'.

THE STRATEGIC SIGNIFICANCE OF INFLUENCERS AND DESIGN THINKING IN CREATING AN INTEGRATED USER EXPERIENCE

ABSTRACT

In recent times, influencers have become important segments of digital marketing. Conveying the marketing message to younger customers is a challenging task for marketing department managers. This paper examines the issue of the strategic position of influencers and the integration of the concept of design thinking into digital marketing and the creation of an integrated user experience. The paper focuses on the creation of entertainment value for customers through the content that influencers market, thus building a close and high-quality relationship with followers. The importance of influencers and sponsored content on Instagram is emphasized in order to increase marketing efficiency. The paper also presents the results of the primary research. The aim of the research was to examine the opinions and attitudes of consumers about influencers and their influence on purchasing decisions. Correlation with the concept of design thinking, which through creative problem solving helps to understand the needs of people for whom a product or service is created, is also explored. The practical implications of the paper are reflected in the contribution to knowledge relevant to the introduction of an integrated user experience, which is carried out through user experience study maps, whereby interactions are monitored and data collected in order to build consistent customer profiles with the aim of ultimately providing them with a complete shopping experience. In the last part of the paper, authors give a critical review of the research results, concluding remarks and guidelines for further research.

KEYWORDS: influencer, influencer marketing, design thinking, customer experience, Customer Jorney Map - CJM

JEL klasifikacija: M15**,** M31

1. UVOD

Tijekom proteklih nekoliko godina djelovanje osoba koje su uzor te koje imaju utjecaj na društvo ogleda se kroz pridobivanje pažnje korisnika društvenih mreža te kakvoću i veličinu baze pratitelja. Taj fenomen naziva se *influencer marketing*, a važnost ovog alata na području digitalne tržišne komunikacije raste iz dana u dan. Ovaj znanstveni rad proizlazi iz izvršenog primarnog istraživanja u diplomskom radu „Influencer marketing“ (Ojurović Čačić, 2022) koje je nadopunjeno dodatnim znanstvenim tezama. Cilj istraživanja je otkrivanje stavova potrošača o influencerima i jačine utjecaja istih na njihove kupovne navike potrošača, ali i otkrivanje veze i utjecaja koncepta dizajnerskog načina razmišljanja (*design thinking*) u digitalni marketing, specifično na primjeru influencer marketinga. Posebno se istražuje i pitanje je li influencer marketing operativni 'alat' digitalnog marketinga ili je riječ o novom segmentu marketinga koje za poduzeća ima strateško značenje.

U radu se polazi od hipoteze da je za učinkovite marketinške rezultate potrebno cjelovito korisničko iskustvo koje uključuje tehnologiju, digitalni marketing i holistički pristup te od teze da potrošači ne gledaju pozitivno na sponzorirane objave. Influencer marketing je novo područje marketinga koje za poduzeća ima strateško značenje.

Ograničenje istraživanja ovog rada je mali uzorak ispitanika jer je istraživanje uključivalo mlađu populaciju koja svakodnevno koristi društvene mreže.

2. POJAM INFLUENCERA I STRATEŠKO ZNAČENJE INFLUENCER KOMUNIKACIJE

Još od davnina društvo, odnosno čovjek teži stvaranju uzora u pojedincu i idoliziranju istog. Nekada su se ljudi ugledali na pojedince koji su imali važne pozicije, a s vremenom su se ugledali i na pjevače, glumce i druge osobe koje su bile istaknute svojim uspjehom. U novije vrijeme popularnost i simpatije sve više dobivaju *influenceri*, koji su postali jedan od značajnih faktora digitalnog marketinga. Stručnjaci iz područja marketinga došli su do spoznaje da ljudi, odnosno kupci više vjeruju preporukama bliskih osoba, prijatelja, osoba s kojima se poistovjećuju ili osoba čije djelovanje ima određenu težinu ovisno o njihovom položaju, ugledu i sl. nego klasičnim oglašivačkim porukama.

Geyser (2022) u svom radu navodi da se influencer može definirati kao „osoba koja posjeduje moć kojom može utjecati na kupovne odluke drugih zbog posjedovanja autoriteta, položaja, znanja ili dobrog odnosa sa svojom publikom“. Autori Enke i Borchers (2019:1) u svom radu navode da se influenceri na društvenim mrežama definiraju kao „akteri treće strane koji su uspostavili značajan broj relevantnih odnosa s određenom kvalitetom i utjecajem na organizacijske dionike kroz proizvodnju sadržaja, distribuciju sadržaja, interakciju i osobni nastup na društvenoj mreži“.

Geyser (2022) navodi: „Važno je spomenuti da influenceri nisu samo marketinški alat, već su i poveznica društvenih odnosa koju brendovi mogu iskoristiti za stvaranje suradnje radi postizanja svojih marketinških ciljeva. Influenceri su ljudi koji su svoju reputaciju izgradili određenim znanjem ili iskustvom u nekom području ili o nekoj temi. Redovno objavljuju postove na društvenim platformama koje preferiraju i dobivaju velik broj sljedbenika koji dijele entuzijazam i isti interes s influencerom. Ti sljedbenici pomno prate postove i stajališta influencera što je prepoznato od strane marketinških stručnjaka koji su shvatili da influenceri stvaraju trendove i potiču svoje pratitelje da kupe proizvode koje oni promoviraju.“ Uz pomoć postova, tweetova i drugih oblika poruka influenceri imaju mogućnost izravnog utjecaja na kupovne navike svojih pratitelja. Mogućnost influencera da utječe na ponašanje pratitelja ogleda se kroz doseg objavljenih postova, relevantnost influencera i konačne rezultate kampanje. Iako se influenceri klasificiraju u više kategorija, njihov cilj je isti: stvaranje bliskog i kvalitetnog odnosa sa što većim brojem pratitelja s ciljem ostvarivanja profitabilnih suradnji s poduzećima.

Recentni radovi iz područja marketinga propituju tezu o strateškom značenju influencera, utemeljeno na činjenici da društvene mreže u digitalnom marketingu poprimaju sve veće značenje. Tako, primjerice, autori Enke i Borchers (2019) zalažu se za razvoj konceptualnog okvira za stratešku komunikaciju influencera na društvenim mrežama. Osobito se oslanjaju na rezultate istraživanja koji identificiraju vanjske resurse kojima društveni mediji doprinose suradnji organizacije i influencera. Koriste se tim nalazima kako bi sustavno razvili funkcijske definicije influencera i njihove strateške komunikacije na društvenim mrežama. Strateška komunikacija na društvenim mrežama definira se kao „svrhovita upotreba komunikacije od strane organizacija ili influencera na društvenim mrežama kojom se obavljaju aktivnosti od strateškog značaja za organizacijske ciljeve“ (Enke i Borchers, 2019:1). Influenceri i strateška komunikacija na društvenim mrežama smještaju se tako u širi okvir strateškog komuniciranja.

„Tijekom i nakon obavljene kampanje, odnosno suradnje s influencerom potrebno je izmjeriti rezultate iste kako bi se saznala njena uspješnost. Od velike je koristi ako tvrtka ima jasno određene KPI-ove (ključne pokazatelje uspješnosti) koje želi postići pa ih može jednostavno usporediti s ostvarenim rezultatima oglašavanja. Potrebno je usporediti, proučiti i interpretirati izmjerene rezultate kampanje.“ (Simonova, 2021).

3. INFLUENCER MARKETING I STAVOVI POTROŠAČA O INFLUENCERIMA

Influencer marketing noviji je marketinški koncept. Ewers (2017) je proveo online eksperiment koji se fokusirao na učinke pojedinih tipova influencera, uloge sponzorstva i plasmana proizvoda na vjerodostojnost poruke te stavove potrošača prema brendu i namjeri kupnje. Rezultati su dokazali učinkovitost sponzorstva za tvrtke i influencere. Naime, učinkovitost sponzorirane objave ovisi o sadržaju teksta objave i njenoj popularnosti na društvenoj mreži, tipu influencera, tome je li naglašeno da je objava sponzorirana i tome kako je proizvod pozicioniran na tržištu. U tom smislu, influencer je jedan od najvažnijih izbora koje marketinški stručnjaci moraju napraviti, pri čemu je vjerodostojnost izvora važan kriterij odabira.

Sammis, Lincoln i Pomponi (2015) navode kako je influencer marketing „u isto vrijeme i umjetnost i znanost o angažiranju osoba koje posjeduju određenu moć na društvenim mrežama i svojim utjecajem šire poruke o nekom brendu u obliku sadržaja koji je sponzoriran od strane tog istog brenda“. Prema definiciji koju navodi Isosuo (2016:3) „influencer marketing podrazumijeva suradnju nekog brenda s online influencerom s ciljem promocije nekog proizvoda ili usluge“. Određeni oblici suradnje između brendova i influencera sklapaju se isključivo zbog poboljšanja prepoznatljivosti i aktualnosti brenda (Geyser, 2022). Imati utjecaj znači mnogo više od posjedovanja velikog broja pratitelja. Bitan je odnos između pratitelja i influencera, kao i stručnost te kredibilitet istog. (Sammis, Lincoln i Pomponi, 2015).

Jedan od važnijih ciljeva influencer marketinga je doprijeti do određenih skupina potrošača. Prenošenje marketinške poruke mlađim kupcima izazovan je zadatak čak i u najboljim vremenima. Jedna od ciljanih skupina na koju influenceri imaju značajan utjecaj su mlađe generacije, a posebno djeca. Umjesto gledanja televizije, slušanja radija i čitanja časopisa, nove generacije gledaju streaming servise kao što je Netflix, slušaju Spotify i oslanjaju se na Reddit. Ove promjene dovele su do dva glavna marketinška kanala: vanjskog oglašavanja poput billboarda i mobilnog oglašavanja, posebno na platformama društvenih medija kao što su Instagram ili TikTok. Na Instagramu je 60% korisnika u SAD-u mlađe od 34 godine, a na TikToku gotovo 40% korisnika čine tinejdžeri između 10 i 19 godina. Ovaj pomak prema Instagramu i TikToku, kao i stranicama kao što je Snapchat, posljednjih je godina doveo do razvoja cijele industrije influencer društvenih medija i marketinških agencija za influencere (Haenlein et al, 2020). Dok gledaju YouTube ili skrolaju kroz svoje aplikacije društvenih medija, djeca i mlađa populacija su sve više izloženi praksama ugrađenog oglašavanja, koje se pojavljuje u zabavnom sadržaju koji objavljuju influenceri na društvenim mrežama. Popularni influenceri koji su stekli određeni status slavnih djeci i mlađoj populaciji predstavljaju vrstu uzora. Stoga su oni voljni poistovjetiti se s njima tako što preuzimaju njihov stil života, stavove i uvjerenja, uključujući i ona vezana uz proizvode koji se pojavljuju na društvenim mrežama. (De Veirman et al, 2019)

Odabir 'pravog' influencera postaje dakle iznimno bitan, osobito u okruženju u kojem jednostavne mjere (kao što su broj pratitelja ili stope angažmana) mogu biti pristrane i pogrešne.

Kako bi osigurali da objava na Instagramu bude više od plasmana proizvoda, tvrtke moraju identificirati influencere koji mogu doprijeti do relevantne zajednice te koji stvarno i autentično koriste proizvode koje promoviraju. Tvrtke, stoga, trebaju potrošiti određeno vrijeme kako bi informirale influencere i 'udubile ih' u brendove koje bi trebali zagovarati (Haenlein et al, 2020). Kako bi influencer marketing u poduzeću bio uspješan, potrebno je pažljivo i detaljno razmisliti o pristupu influenceru, a marketinški tim poduzeća mora biti organiziran, osmisliti strategiju, plan, budžet i provesti određeno vrijeme analizirajući ključne čimbenike influencer marketinga. (Geyser, 2022).

Potrošači su usvojili oprezan pristup pri određivanju vjerodostojnosti informacija koje dobivaju od influencera. Ovaj oprez mogao bi se objasniti sviješću potrošača o praksama oglašavanja, a također bi mogao biti pod utjecajem nedavnih kontroverzi i skandala u industriji influencer marketinga. Posljednjih nekoliko godina bilježi se povećana diskusija o odgovornostima influencera, njihovoj autentičnosti i smjernicama za oglašavanje od strane influencera. Uzrok tome je rastuća popularnost influencera, ali i tjeskobe oko porasta 'lažnih vijesti' i brojnih slučajeva obmanjujućeg oglašavanja koje ponekad promoviraju influenceri (Segova, 2020). Pratitelje zanimaju iskrenost i autentičnost, što dovodi do toga da se žele povezati sa svojim omiljenim influencerom i u stvarnom životu. Sve više tvrtki stoga potiče influencere da organiziraju sastanke uživo, u rasponu od jednostavnih 'meet and greet' događaja u kafićima do nastupa ili podcast snimaka uživo. Ovakva pojavljivanja uživo od velike su važnosti za tvrtke (Haenlein et al, 2020). Dakle, naglasak je na stvaranju bliskog i kvalitetnog odnosa influencera i njihovih pratitelja, što potkrjepljuju i recentna istraživanja.

Tako primjerice Segova (2020) istražuje stavove potrošača o influencerima i sponzoriranom sadržaju na Instagramu. Rezultati su pokazali da potrošači preferiraju sponzorirani sadržaj u odnosu na tradicionalne online i offline tehnike oglašavanja, a jedan od glavnih razloga za ovu preferenciju je osobni odnos koji oni mogu uspostaviti s influencerima. Kvantitativna komponenta istraživačkog projekta promatrala je hoće li potrošači koji kupuju na Instagramu poslušati preporuke influencera i imati pozitivnu reakciju na sponzorirane objave. Pokazalo se da su intervjuirani korisnici Instagrama bili vrlo svjesni prakse oglašavanja i mogli su otkriti sponzorirani sadržaj čak i kada nije on bio naznačen kao takav. Ispitanici su stoga u većini slučajeva sadržaj influencera u svrhu promicanja nekog brenda smatrali oglašavanjem, a manje od trećine njih smatralo je objave koje prikazuju proizvod preporukama ili podizanjem svijesti o proizvodu ili usluzi.

Navedeno ukazuje da potrošači postaju sve više medijski pismeni, što znači da su vrlo svjesni influencer marketinga kao promotivne metode, ali su i uvjereni su u svoju sposobnost prepoznavanja plaćenog oglašavanja. Iako postoji veća vjerojatnost da će potrošači ignorirati promotivni sadržaj, sadržaj influencera koji nudi vrijednost osim istaknutog proizvoda može se svidjeti potrošaču iz perspektive zabave. U ovoj studiji je pokazano i da je, dok su sudionici imali neutralnu reakciju na namjeru oglašavanja, vjerojatnije da će se osjećati nezainteresirano zbog promotivnog tona glasa u poruci nego zbog same činjenice sponzorstva.

Spomenuto istraživanje pokazalo je i da su influenceri uspjeli kombinirati sadržaj koji nudi zabavnu vrijednost s promotivnim porukama u sponzoriranim postovima. Kako su reklamni sadržaji influencera usredotočeni na prenošenje iskustava iz stvarnog života, fokus nije samo na oglašenom proizvodu ili usluzi već i na narativnim detaljima priča, iskustava i osjećaja koje influenceri evociraju dok pripovijedaju svoja iskustva na internetu. Ovo mijenja pristup marketingu na društvenim mrežama, gdje vrijednost koju oglas nudi uvelike naglašava njegov zabavni sadržaj, a ne samo proizvod. Ova vrsta sadržaja privlačnija je za potrošače i nudi im više informacija o tome kako se proizvod koristi. Influenceri na društvenim mrežama također

mogu izgraditi međuljudske odnose sa svojim sljedbenicima i stvoriti intimnost koju brendovi i influenceri kapitaliziraju putem partnerskih ugovora (Segova, 2020).

Korištenjem oglašavanja pomoću influencera poduzeće može dakle lakše doći do relevantne publike, izgrađuje povjerenje korisnika i vjerodostojnost brenda, skraćuje ciklus prodaje, ali i smanjuje troškove oglašavanja. Ipak, treba voditi računa i o nedostacima tog oblika oglašavanja koji se ogledaju prvenstveno kroz rizik suradnje s pogrešno izabranim influencerima što može dovesti do znatne, nepopravljive reputacijske štete. Često influenceri „kupuju" lažne pratitelje i ne ulažu maksimalan trud u sponzorirane objave što dovodi do loše reputacije brenda. S druge strane, ponekad se može dogoditi da influencer iskoristi sva svoja znanja i vještine, ali ideja brenda nije dobra. Postoje brojni primjeri gdje su brendovi imali loše, a često i uvredljive reklame koje su dovele do narušavanja reputacije influencera. Korisnici društvenih mreža i pratitelji influencera imaju različita mišljenja i stavove o tom načinu oglašavanja, ali može se zaključiti da korisnicima društvenih mreža uglavnom ne smetaju sponzorirane objave od strane influencera, ukoliko su one iskrene i vjerodostojne (Ojurović Čačić, 2022).

3.1. REZULTATI PRIMARNOG ISTRAŽIVANJA O MIŠLJENJU I STAVOVIMA POTROŠAČA I UTJECAJU INFLUENCERA NA KUPOVNE ODLUKE POTROŠAČA

U svom diplomskom radu Ojurović Čačić (2022) je izvršila anketno istraživanje kojem je primarni cilj bio saznati mišljenja i stavove potrošača u Republici Hrvatskoj prema influencerima i sponzoriranim objavama te imaju li influenceri utjecaj na njihove kupovne navike. Korišteni su primarni podaci prikupljeni online anketama uz pomoć programa Google Forms te je distribuiran u digitalnom obliku putem društvenih mreža. Na početku samog upitnika tražile su se osnovne demografske informacije o ispitaniku poput dobi, spola i razine obrazovanja, a ostatak upitnika povezan je s tematikom istraživanja. U istraživanju je sudjelovalo 165 ispitanika različitih demografskih obilježja te su svi ispunjeni upitnici bili važeći. Istraživanje je provedeno u vremenskom razdoblju od 08. rujna 2022. do 11. rujna 2022. Ciljana populacija su bile osobe od 18 do 30 godina koje svakodnevno koriste društvene mreže. Na početku anketnog upitnika bila je navedena definicija influencera s ciljem upoznavanja ispitanika s tim pojmom. Ispitanici su imali mogućnost neodgovaranja na pitanja ukoliko se nisu osjećali ugodno odgovarati na njih.

U nastavku su prikazani rezultati istraživanja. Ispitanici su različite dobi, a najveći broj ispitanika (63,6 %, odnosno 105) ima od 18 do 24 godine. 45 ispitanika (27,3 %) ima između 25 i 35 godina. 7 ispitanika ima manje od 18 godina, 5 ispitanika ima između 36 i 45 godina, a 3 ispitanika ima više od 46 godina. U rješavanju anketnog upitnika sudjelovali su ispitanici obaju spolova. Anketu je riješilo više osoba ženskog spola, njih 119, odnosno 72,6 % uzorka. Osoba muškog spola bilo je 45, odnosno 27,4 % u uzorku ispitanika. Najveći broj ispitanika, njih 79 (47,9 %) izjasnilo se da je trenutačno u statusu studenta/ice. 68 ispitanika, odnosno 41,2 % uzorka je zaposleno. 10 ispitanika (6,1 %) su učenici, a 8 (4,8 %) ispitanika je u trenutku ispunjavanja ankete nezaposleno. Čak 100 ispitanika (60,6 %) kao najviši završen stupanj obrazovanja ima srednju školu. 27 ispitanika (16,4 %) ima završen preddiplomski studij, a 22 ispitanika (13 %) ima završen diplomski studij. 9 ispitanika (5,5 %) ima završen stručni studij, dok najmanji broj ispitanika (njih 7, odnosno 4,2 %) ima završenu osnovnu školu.

Na pitanje koriste li ispitanici društvene mreže poput Facebooka, Instagrama i sl., svih 165 ispitanika odgovorilo je potvrdno. Ova informacija pokazuje da su, unatoč različitim demografskim obilježjima, društvene mreže toliko zastupljene u društvu da ih je nemoguće izbjeći i iz tog razloga ih je potrebno iskoristiti u marketinške svrhe na najbolji mogući način.

Iako se koriste u različite svrhe, društvene mreže su platforme na kojima se odvija velika količina komunikacije između korisnika što rezultira globalnim povezivanjem korisnika.

U anketi su se ispitivale tvrdnje koje istražuju stavove ispitanika prema influencerima. Grafikoni 1-8 prikazuju stavove ispitanika o različitim aspektima oglašavanja influencera, a za mjerenje stavova korištena je Likertova ljestvica stavova koja sadrži pet stupnjeva, a to su:
1 - Uopće se ne slažem, 2 - Uglavnom se ne slažem, 3 - Niti se slažem niti se ne slažem, 4 - Uglavnom se slažem, 5 - U potpunosti se slažem.

Grafikon 1. „Influencerima koji imaju veliki broj pratitelja više vjerujem."

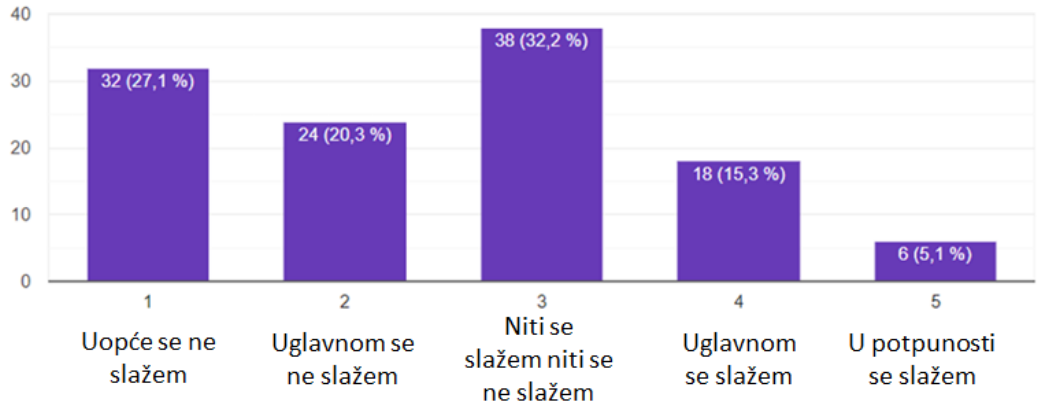

Izvor: Ojurović Čačić (2022)

Može se uočiti da je najveći broj ispitanika (njih 38, odnosno 32,2 %) bio za stupanj 3, odnosno za stupanj gdje se ispitanici niti slažu niti ne slažu s tvrdnjom. Zatim slijedi stupanj 1 kojim se 32 ispitanika (27,1 %) uopće ne slaže s navedenom tvrdnjom. Najmanji broj ispitanika (njih 6, odnosno 5,1 %) odgovorilo je da se u potpunosti slaže s tvrdnjom (grafikon 1).

Grafikon 2. „Influencerima koji objavljuju pozitivne i negativne strane proizvoda/usluge više vjerujem i potiču me da usvojim njihove savjete."

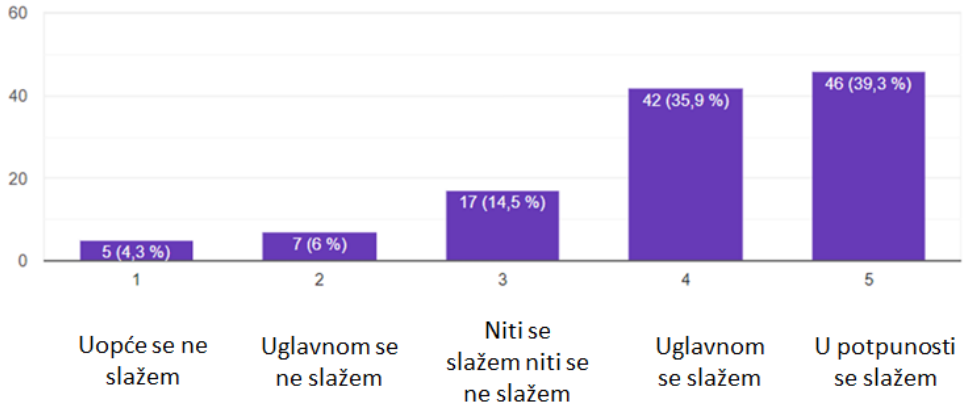

Izvor: Ojurović Čačić (2022)

Kada je riječ o ovom pitanju, većina ispitanika koja je odgovorila na pitanje se uglavnom slaže (njih 42) ili potpuno slaže (njih 46) s navedenom tvrdnjom. Samo 5 ispitanika se uopće ne slaže s tvrdnjom da više vjeruju influencerima koji objavljuju prednosti i nedostatke proizvoda ili usluge (grafikon 2).

Grafikon 3. „Influenceri koji imaju previše sponzoriranih objava nisu vjerodostojni.“

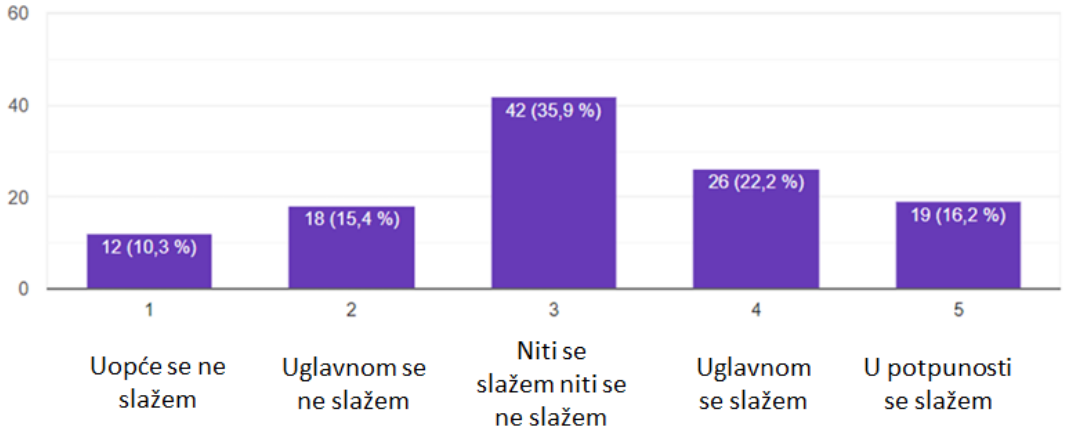

Izvor: Ojurović Čačić (2022)

Kada je riječ o ovoj tvrdnji, najveći broj ispitanika (njih 42) izjasnio se da se niti slaže niti ne slaže s tim da se, ako influenceri imaju prevelik broj sponzoriranih objava, njihova vjerodostojnost smanjuje. 19 ispitanika se u potpunosti slaže s tom tvrdnjom, a 12 ispitanika se uopće ne slaže (grafikon 3).

Grafikon 4. „Sponzorirane objave me upoznaju s brendovima i proizvodima za koje prije nisam znao/la.“

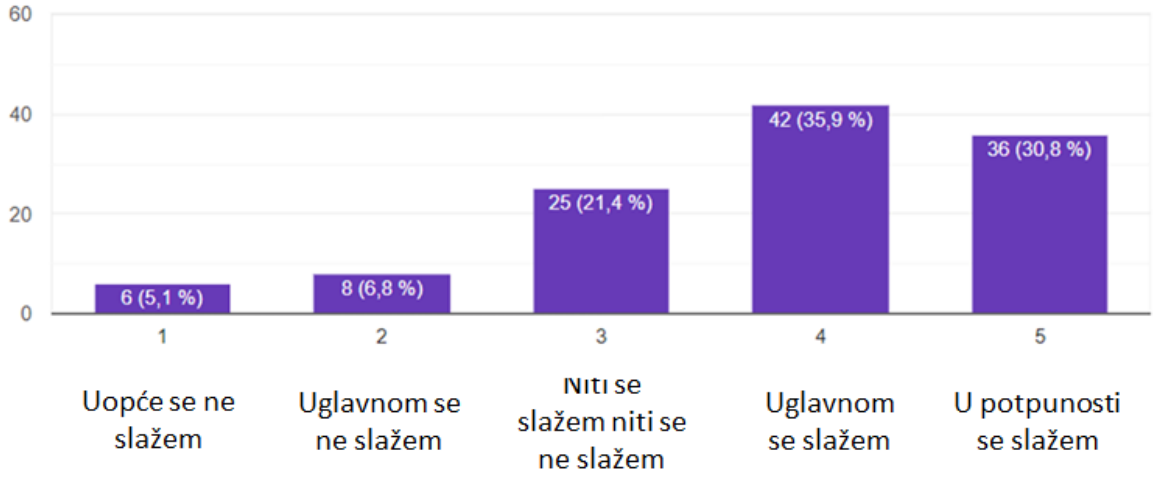

Izvor: Ojurović Čačić (2022)

I za ovu tvrdnju ispitanici imaju većinom pozitivan odgovor. Njih 42 se uglavnom slaže da će uz pomoć sponzoriranih objava upoznati nove brendove, a njih 36 se u potpunosti slaže s ovom tvrdnjom. 6 ispitanika se uopće ne slaže, dok je 25 ispitanika neodlučno. Ipak, uočava se veća naklonost pozitivnim odgovorima što govori da se korisnici na društvenim mrežama mogu upoznati s novim brendom (grafikon 4).

Grafikon 5. „Bilo bi mi draže da na društvenim medijima nema sponzoriranih objava.“

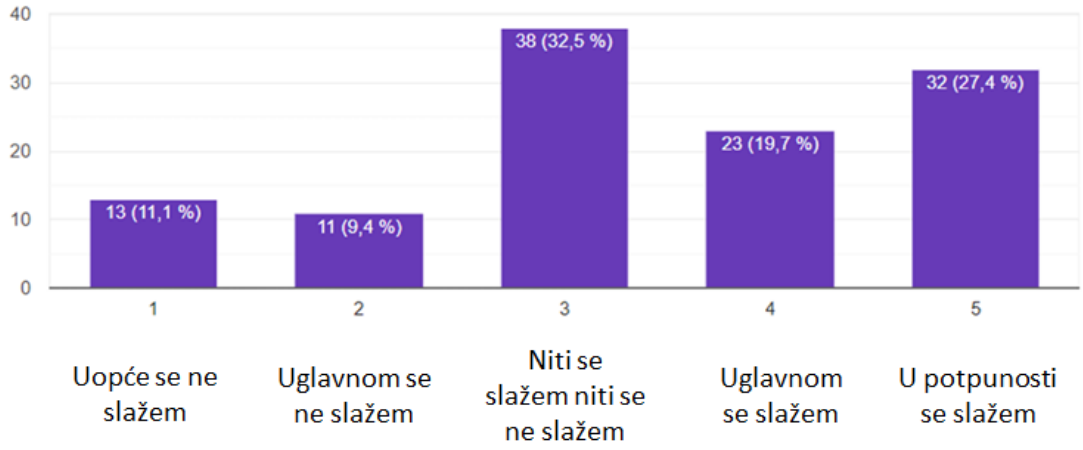

Izvor: Ojurović Čačić (2022)

38 ispitanika navodi da im je svejedno ima li na društvenim medija sponzoriranih oglasa, dok bi 32 ispitanika potpuno preferirala da ne postoje sponzorirani oglasi. S druge strane, njih 13 se ne slaže s tom tvrdnjom. Može se uočiti da je veći postotak onih kojima sponzorirani oglasi na društvenim mrežama smetaju (grafikon 5).

Grafikon 6. „Bitnija mi je preporuka prijatelja i obitelji od preporuke omiljenog influencera na društvenim mrežama.“

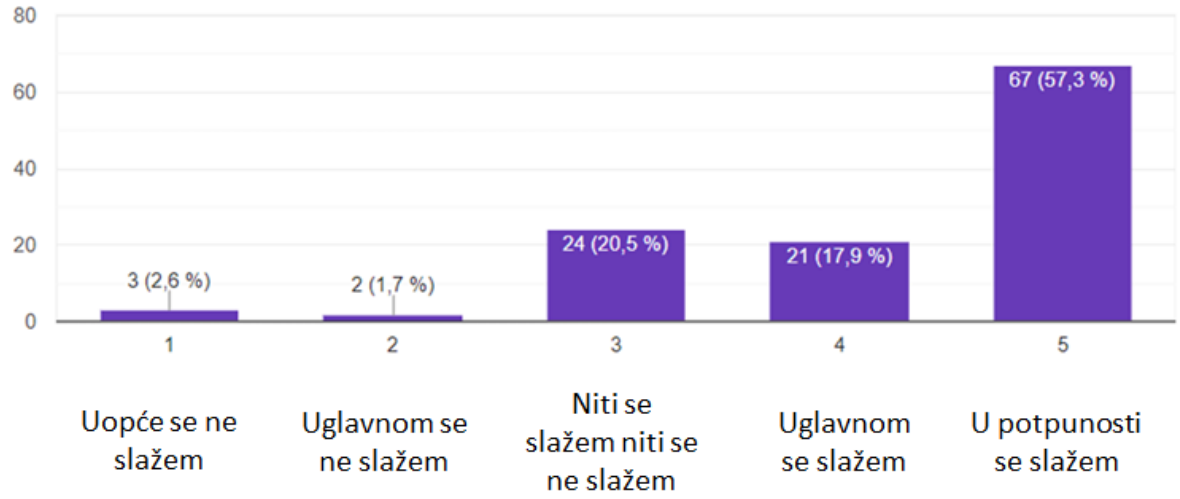

Izvor: Ojurović Čačić (2022)

Kada je riječ o ovoj tvrdnji, uočava se većinska naklonost preporukama bliskih prijatelja i obitelji u odnosu na preporuke influencera. Njih 67 se u potpunosti slaže s ovom tvrdnjom, a 21 ispitanik navodi da se uglavnom slaže s navedenom tvrdnjom. Samo 3 ispitanika navode da se ne slažu s ovom tvrdnjom, dok 24 ispitanika navode da se niti slažu niti ne slažu (grafikon 6).

Grafikon 7. „Veće povjerenje imam u influencere na društvenim mrežama nego u oglase putem klasičnih medija (TV, radio, novine).“

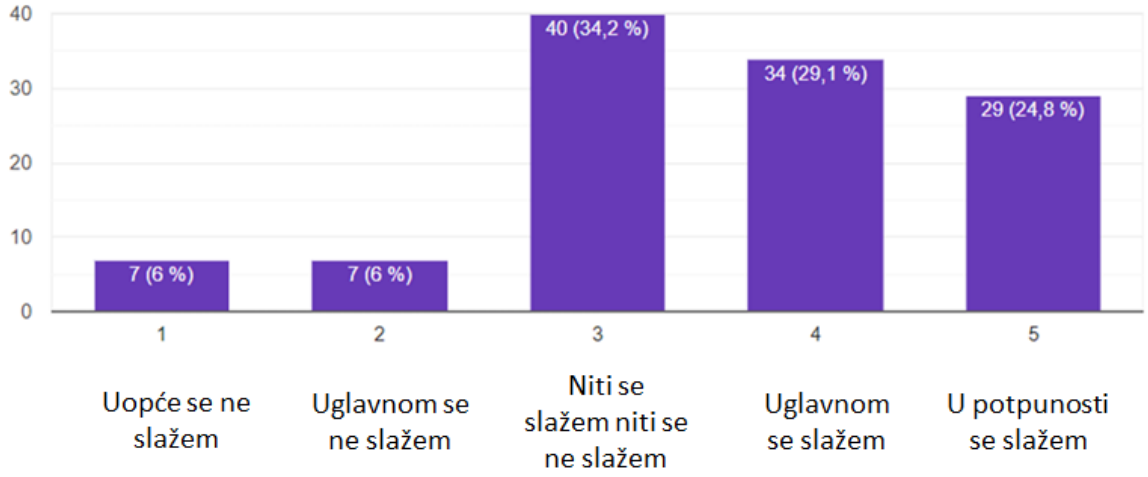

Izvor: Ojurović Čačić (2022)

Ova tvrdnja rezultira velikom razlikom među odgovorima. 40 ispitanika navodi da je neodlučno kada je riječ o ovoj tvrdnji, a većina odgovora naklonjena je influencerima u odnosu na tradicionalan oblik promoviranja. 29 ispitanika se potpuno slaže s ovom tvrdnjom, a njih 34 navodi da se djelomično slaže s tvrdnjom (grafikon 7).

Grafikon 8. „Smatram da svi influenceri trebaju označiti kad je objava sponzorirana.“

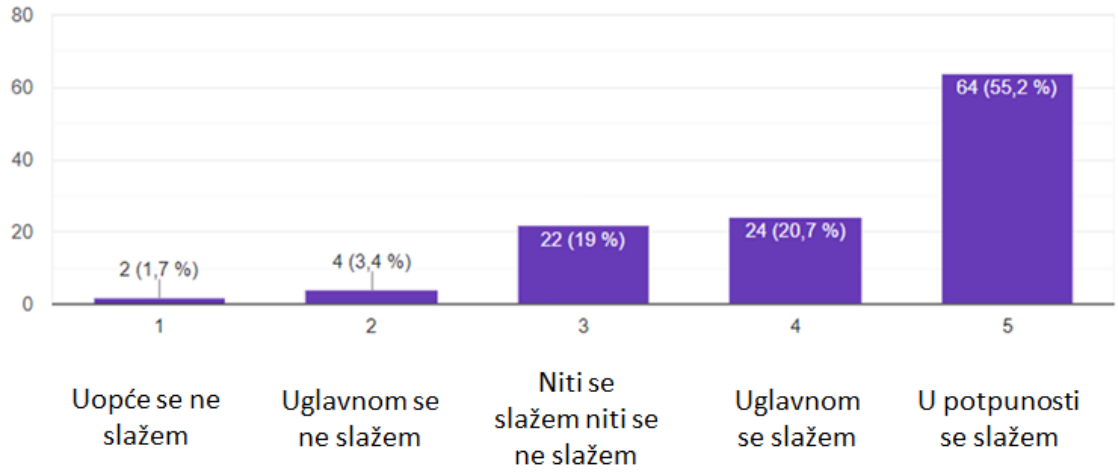

Izvor: Ojurović Čačić (2022)

Posljednja postavljena tvrdnja označava da se najveći broj korisnika društvenih mreža slaže s tvrdnjom da influenceri trebaju naznačiti da je objava sponzorirana. Samo 2 ispitanika se uopće ne slaže s tom tvrdnjom, dok 22 ispitanika navodi da se niti slažu niti ne slažu (grafikon 8).

Može se zaključiti da, iako je influencer marketing relativno nov i još uvijek nedovoljno istražen pojam, prikazani rezultati primarnog istraživanja pokazuju da je većina ispitanika upoznata s ovim fenomenom. Nadalje, ispitanici su u istraživanju odgovorili da broj pratitelja influencera nije najvažniji faktor prilikom odabira influencera. Ako influencer ima veći broj pratitelja, ispitanici naime smatraju da to ne znači nužno da mu publika više vjeruje. Najveći broj ispitanika više vjeruje influencerima koji će objaviti i pozitivne i negativne strane

proizvoda ili usluge. Poduzeća vjerojatno ne vole ovakav pristup, ali potrošači će vrlo vjerojatnije kupiti proizvod ako influencer tvrdi da je on odlične kvalitete iako se, primjerice, nalazi u neprivlačnoj ambalaži. Kada je riječ o vjerodostojnosti influencera ovisno o broju sponzoriranih objava, mišljenja ispitanika su različita. Najveći broj ispitanika je neodlučan, ali postoji određeni broj njih koji smatra da s rastom sponzoriranih objava, pada vjerodostojnost influencera. Velik broj ispitanika je putem sponzoriranih objava influencera upoznao nove brendove i proizvode. Većina ispitanika u uzorku navodi da bi voljela da na društvenim mrežama nema sponzoriranih objava, što je gotovo nemoguće.

Ispitanici u uzorku potvrdili su da im je od preporuke influencera bitnija preporuka obitelji i prijatelja. Iako je ovakav rezultat očekivan i vjerojatno ništa ne može promijeniti ovo mišljenje, influenceri se trebaju dodatno angažirati kako bi ostvarili kvalitetan odnos s pratiteljima. Trebaju bolje komunicirati, ponekad nagrađivati svoje pratitelje i pokazati im zahvalnost, što će rezultirati osjećajem bliskosti i prijateljstva. S druge strane, ispitanici imaju mnogo veće povjerenje u influencere nego u oglase putem tradicionalnih medija, što je svakako bolje za poduzeće s obzirom da je suradnja s influencerom najčešće jeftinija nego reklama na nekoj poznatoj televizijskoj postaji.

Ono s čim se većina ispitanika u istraživanju složila je tvrdnja da bi influenceri trebali označiti svaku objavu koja je sponzorirana. Neke države su definirale zakonsku regulativu vezanu uz ovaj problem, što u Republici Hrvatskoj nije slučaj. Određenom broju ispitanika ne smetaju sponzorirane objave, ali smatraju da iste treba označiti. S druge strane, neki ispitanici smatraju da sponzoriranim objavama nije mjesto na društvenim mrežama te da iste treba ukinuti. Navođenjem informacije da je objava sponzorirana, influencer pokazuje da je otvoren i iskren sa svojim korisnicima, što je ključan čimbenik prilikom stvaranja dobrog i lojalnog odnosa influencera s pratiteljima.

4. INTEGRIRANO KORISNIČKO ISKUSTVO U KONTEKSTU DRUŠTVENIH MEDIJA

Pojava društvenih medija promijenila je način na koji tvrtke pristupaju klijentima, a tradicionalni poslovni model marketinga kupaca promijenio se u onaj u kojem se kupac bavi proizvodom ili uslugom. Tvrtkama je potrebna spremnost te znanje kako koristiti podatke i dodirne točke za izradu 'karte putovanja korisnika' radi poboljšanja korisničkoh iskustva. Kupci su u interakciji s tvrtkama kroz različite dodirne točke koje je važno objediniti u jednistveno korisničko iskustvo. (Zaytech, 2023)

U aktualnom razdoblju sve složenijeg ponašanja kupaca razvija se jače razumijevanje korisničkog iskustva i 'korisničkog putovanja' na društvenim medijima. Kupci sada komuniciraju s tvrtkama putem brojnih dodirnih točaka u više kanala i medija, a iskustva kupaca sve više su društvene prirode. Ove promjene zahtijevaju od tvrtki da u stvaranju i pružanju pozitivnih korisničkih iskustava integriraju više poslovnih funkcija, pa čak i vanjske partnere. Kako bi se postigao ovaj cilj, ispituju se postojeće definicije i konceptualizacije korisničkog iskustva kao konstrukta te se istražuje i povijesna perspektiva korijena korisničkog iskustva, što dovodi do učinkovitijeg upravljanja korisničkim iskustvom. (Lemon i Verhoef, 2016).

Tvrtke dakle sve više stavljaju naglasak na holističko korisničko iskustvo, no u tu svrhu potrebno je definirati odgovarajuće mjere i marketinške politike. Iskustvo kupca emocionalni

je koncept čiji se rezultat manifestira na različite načine ovisno o sektoru. (Ponnam, 2014). Kupci danas komuniciraju s tvrtkama putem velikog broja različitih kanala, od društvenih medija preko mobilnih uređaja do fizičke trgovine, pri čemu tvrtke moraju prikupiti podatke iz širokog spektra izvora. Korištenjem analitičkih alata, kao što su mape proučavanja korisničkog iskustva, suvremene tvrtke mogu ponuditi jedinstveno korisničko iskustvo. Mapa korisničkog putovanja počinje s proizvodom ili markom. To je grafički ili narativni prikaz odnosa kupca s tvrtkom, proizvodom ili uslugom. Prikazuje interakcije korisnika s tvrtkom tijekom protoka vremena i kroz različite kanale isporuke usluga. Iako se, površno gledano, čini da su mnoge organizacije integrirale korisničko iskustvo u sustav upravljanja poslovnim procesima, prema Misiak (2018) samo one organizacije koje implementiraju mapu korisničkog putovanja stječu jasnu konkurentsku prednost. Povećani naglasak na koncept korisničkog iskustva dobar je znak jer prisiljava organizacije da uzmu u obzir pogled izvana prema unutra. (Zaytech, 2023)

U svom blogu autori Magic i Helmstetter (2023) pišu o tome kako odlično korisničko iskustvo počinje odličnim iskustvom zaposlenika, odnosno dokazuju da zadovoljstvo i pozitivno iskustvo zaposlenika na dnevnoj bazi utječe na pozitivan dojam o brendu. Napominju kako je pri tom bitan timski rad i podrška svih članova tima. Timska dinamika mjeri se konceptom psihološke sigurnosti. Zaposlenici trebaju imati beneficije, dobru plaću i mogućnosti napredovanja, ali se također trebaju osjećati uključenima u proces rada te aktivno sudjelovati u iskazivanju mišljenja i osjećati se kao dio usklađenog tima. Zadovoljstvo zaposlenika utječe na zadovoljstvo kupaca, a cilj je podići korisničko iskustvo od dobrog do izvrsnog. Kako bi se to postiglo potrebno je kod zaposlenika graditi mnoštvo 'mekih' vještina, a ponajprije sposobnost osluškivanja kupaca i njihovih potreba.

Interakcija korisnika s tvrtkom u suvremenom kontekstu međutim uključuje dodatne dodirne točke. Organizacijama često nedostaju jasne procedure za standardiziranje i optimiziranje korisničkog iskustva u svim dodirnim točkama korištenjem podataka o korisnicima. Poboljšanje korisničkog iskustva ne bi trebao biti jednokratan napor, već ono bi trebalo postati kontinuirani proces koji se prilagođava i ide u korak s nadolazećom tehnologijom. Nadalje, tradicionalni poslovni modeli marketinga prema kupcima moraju se promijeniti. Suvremeni društveni mediji mogu biti velik izazov za tvrtke jer su marketinške kampanje osmišljene kako bi omogućile korisniku da aktivno sudjeluje u komunikaciju o proizvodu/usluzi. Potrebno je stoga sustavno pratiti ove interakcije i prikupljati sve relevantne podatke kako bi se izgradili dosljedni profili kupaca kako se u konačnici pružilo cjelovito korisničko iskustvo (Zaytech, 2023).

Suština onoga što razlikuje poslovanje neke tvrtke od konkurencije su poslovni procesi. Upravljanje poslovnim procesima omogućuje komunikaciju različitih segmenata organizacije kako bi se realizirao željeni cilj. Stvaranje korisničkog putovanja omogućuje organizaciji uvid u načine komunikacije s klijentima. Upravljanje poslovnim procesima usmjereno je na podršku modeliranju i automatizaciji poslovnih procesa. Kada se tome doda Business Intelligence, moguće je implementirati brza i isplativa procesna rješenja. Poduzeća trebaju svoje procese uskladiti s 'korisničkim putovanjem kupca', odnosno upravljanje poslovnim procesima usustaviti na smisleniji i održiviji način. Kada se putovanja kupaca kombiniraju s upravljanjem poslovnim procesima, to će dovesti do poboljšanja korisničkog iskustva, tvrdi Zaytech (2023).

5. DESIGN THINKING KAO MARKETINŠKI POSLOVNI MODEL

Marketing i *design thinking* rijetko se povezuju jedno s drugim jer proizlaze iz vrlo različitih područja znanosti i izvora primjene odnosno različitih paradigmi. U svom radu Reinecke (2016) raspravlja o temeljnim sličnostima između ova dva pristupa i ukazuje na to da ova dva gledišta mogu donositi međusobne koristi. *Design thinking* može učinkovito pomoći u ubrzavanju procesa učenja u marketingu, a marketinška znanost može pomoći osigurati da se u *design thinking*-u ne zanemaruju temeljna znanja iz društvenih znanosti.

Design thinking (dizajnersko razmišljanje) je kreativno rješavanje problema koje u marketingu pomaže razumjeti potrebe ljudi za koje se stvara proizvod ili usluga. Uobičajeni aspekti *design thinking*-a su: fokus na korisničko iskustvo, modeli za ispitivanje složenih problema, prototipovi i testiranje, tolerancija na neuspjeh i ciljani izbori o tome što učiniti, a što ne učiniti. *Design thinking* koristi mnoge alate za svoje osnovne procese razumijevanja i promatranja, definiranja točke gledišta (POV - *Point of View*), stvaranje ideja, izradu prototipa i testiranje načina za optimizaciju prilagodbe sustava potrebama korisnika. Divergentno i konvergentno razmišljanje koriste se za definiranje problema i definiranje rješenja, a ova dualnost može se vizualizirati kao model dvostrukog dijamanta. Model d*esign thinking* i s njim povezane strategije mogu dizajnere, poput sistemskih inženjera, pretvoriti u dizajnerske mislioce. (Total digital, 2023)

Schiele i Chen (2018) navode kako marketinški edukatori mogu iskoristiti proces design thinking-a za stvaranje angažiranog i visokoučinkovitog iskustva učenja za studente. Smjernice zadatka koju autori razmatraju na primjeru edukacije studenata marketinga usmjerene su na to da izazovu proces razmišljanja o dizajnu kojim će se, primjerice, kreirati mobilna aplikaciju koja zadovoljava potrebe ciljanih potrošača. Ovaj prilagodljivi zadatak testiran je u dvije skupine marketinških kolegija, a rezultati su pokazali da su studenti, pomoću dizajnerskog razmišljanja, napredovali u područjima empatije, kreativnosti, komunikacijskih vještina, tehnoloških vještina, kritičkog mišljenja i suradnje.

Design thinking, lean startup i marketing visoke tehnologije u sistemskom inženjerstvu analizirani su i procijenjeni u radu Weiland i Knizhnik (2022). Ovi autori ističu potencijal tih alata za poboljšanje procesa inženjeringa sustava i dizajna, suočavanje s izazovima promjene organizacijske kulture, povećanje stope usvajanja nove tehnologije i učinkovitije povezivanje s potencijalnim korisnicima i sponzorima. Višestruki primjeri obuke i korištenja na inicijativi inženjeringa sustava temeljenog na modelu - *Model-Based Systems Engineering* (MBSE)[1] korištenog u vladinoj agenciji pokazuju kako su ovi pristupi kreirani i uspješno korišteni te su pokazali značajne prednosti kao što je poboljšana suradnja te bolja definicija problema i rješenja dizajna. Ovi novi načini razmišljanja dobro su usklađeni sa stvaranjem i korištenjem novih tehnologija i prikladni su za situacije koje uključuju inovacije, neizvjesnost i promjene unutar organizacija.

Vasilieva (2018) je istraživala razinu pronalaska novih alata za analizu skrivenih potreba klijenata pomoću reguliranja slijeda rezoniranja pri donošenju odluka tijekom kreiranja inovativnih projekata. Predlaže pristup izrade mape proučavanja korisničkog iskustva interakcije s proizvodom u kojoj se može koristiti mapa korisničkog iskustva (*Customer Jorney Map* - CJM), metoda trijada i model PEDPL: Pre-Experience, During-Experience, Post-

[1] Model-Based Systems Engineering (MBSE) - je formalizirana metodologija koja se koristi za podršku zahtjevima sustava, dizajnu, analizi, verifikaciji i validaciji povezanim s razvojem složenih sustava te stavlja modele u središte dizajna sustava (raspoloživo na: https://insights.sei.cmu.edu/blog/introduction-model-based-systems-engineering-mbse/, pristupljeno: 04.09.2023.)

Experience, Lost-Experience. Važan segment modela PEDPL je analiza "Lost Experience" („Propuštena iskustva") koji je koristan radi analize procesa izvan razine postojećeg poslovanja, alternative korištenja poznatog proizvoda, proširenje funkcija proizvoda i reinkarnaciju korisničkog iskustva u drugoj ravni, uzimajući u obzir neostvarene karakteristike i interese potrošača (kulturološke karakteristike, sklonosti, navike, tradicije i slično). Ova analiza može uzeti u obzir sve obrasce korisničkog iskustva vezano uz proizvod. Rezultati istraživanja ukazuju na nove pristupe strukturiranju informacija, što je važno za 'uživljavanje' u korisničko iskustvo, razumijevanje problema korisnika i pronalaženje novih rješenja. Znanstvena novost sastoji se od predloženih novih alata za vizualizaciju asocijativnog mišljenja, konstruiranje niza koraka i metoda za proučavanje potrošača, izoliranje problema i razvoj ideje. Rezultati primjene mogu biti upotrijebljeni pri razvoju nove internetske usluge ili mobilne aplikacije ili, primjerice, za razvoj strategije brenda, kada je važno istražiti skrivene potrebe klijenta.

Dosljedno i relevantno korisničko iskustvo izravno je povezano s konverzijom. Kada kupac stupi u kontakt s organizacijom na svim dodirnim točkama i doživi fluidnu uslugu veća je vjerojatnost da će kupiti proizvod ili uslugu. Konverzije se događaju kada posao ispuni ili premaši očekivanja korisnika. Važno je služiti online i offline kupca s istom angažiranošću. Usluživanje jedne skupine kupaca i isključivanje drugih, primjerice, postavlja stvarno ili zamišljeno ograničenje rastu prihoda, prema Porteru (1996). Organizacije često oklijevaju ponuditi dosljedno korisničko iskustvo jer zaobilaze mapu korisničkog putovanja što rezultira fragmentiranim iskustvom kupca (Zaytech, 2023).

6. ZAKLJUČAK

Ovaj rad donosi prilog teoriji i praksi influencer marketinga kao segmenta digitalnog marketinga, posebice u području kreiranja korisničkog iskustva kroz influencer marketinšku komunikaciju, koja u suvremenom kontekstu dobiva stratešku komponentu. Strateško značenje influencera potvrđeno je recentnim istraživanjima gdje se dokazuje da je uloga influencera sve veća u kontekstu izgradnje dugoročnih odnosa s korisnicima društvenih mreža – potencijalnim i stvarnim kupcima proizvoda, ali i osnaživanja i razvoja brenda. Uočava se stoga evolucija koncepta influencer marketinga, koji je započeo tek kao inovativan, gotovo eksperimentalni marketinški alat s ciljem amplifikacije oglašivačkih napora. No on je međutim doživio svojevrsnu evoluciju i danas dostigao svoj rast, a možda i zrelost, što se očituje kroz snažan utjecaj influencera na snagu brenda i odnose s kupcima, što bi trebalo dodatno razraditi kroz daljnja istraživanja.

Primarno istraživanje čiji su rezultati prikazani u radu pokazalo je, s druge strane tržišta, i izvjesnu zrelost i svjesnost potrošača da su obasuti marketinškim porukama, što im je nemoguće izbjeći, posebice na društvenim mrežama, a što su dokazala i prethodna istraživanja. Međutim, u tom procesu influenceri, čini se, ne predstavljaju komponentu smetnje, već dodaju, moglo bi se reći, određeni stupanj ljudskosti u tehnološki prezasićenoj životnoj realnosti prvenstveno mlađih generacija, i to posebice na društvenim mrežama gdje provode ogromnu količinu vremena. Tako, primjerice, ispitanici u istraživanju, uglavnom mladi, ne zamjeraju influencerima to što stječu profit zahvaljujući svojim objavama sve dotle dok su njihove objave i preporuke iskrene i vjerodostojne. Iz tog razloga, tvrtke trebaju birati influencere koji su izgradili posebnu povezanost s pratiteljima i zbog kojih će reputacija brenda samo rasti. Ovakvim modelom poslovanja bit će zadovoljno kako poduzeće, radi poboljšanja učinkovitosti poslovanja, tako i sam influencer zbog svog angažmana, ali i potrošač zbog kvalitetnog

proizvoda ili usluge kojega je kupio uz pomoć i savjet influencera, što mu je smanjilo kupovne rizike te poboljšalo i obogatilo korisničko iskustvo.

Rezultati istraživanja ukazuju stoga na nužnost pažljivog odabira influencera, kao i važnost konzistentnosti poslovne strategije tvrtke i strategije brendiranja sa strategijom angažmana i odabira influencera. Time se još jednom potvrđuje evolucijski napredak influencer marketinga, što je napomenuto ranije, a suvremenim organizacijama je to i signal za implementaciju adekvatne influencer komunikacije u strateške marketinške i brending planove. Time se ovim radom daje i doprinos tezi od hijerarhijskom 'izdizanju' influencer komunikacije s operativne razine na stratešku, o čemu su potrebna daljnja istraživanja i daljnji razvoj konceptualnog okvira u području influencer marketinga.

Konačno, ovaj rad donosi i elementarne teze o integraciji koncepata dizajnerskog razmišljanja i digitalnog marketinga. Dizajnersko razmišljanje se u marketingu može implementirati kako u kreiranju arhitekture influencer komunikacije, tako i u sustavu korištenja alata analitičkog marketinga, posebice u procesu mapiranja kupovnog ‘putovanja’ kupaca. To je danas poduprijeto razvojem nove tehnologije, pri čemu se, osim sada već poznatih i široko korištenih alata kao što su veliki podaci, cloud pohranjivanje podataka, rudarenje podataka, klasteriziranje podataka o klijentima i drugi, kao posebno područje rasprave u digitalnom marketingu nameće korištenje umjetne inteligencije, što predstavlja nesagledIv potencijal. Dizajnersko razmišljanje se pritom čini jednim od ključnih koncepata, jer obuhvaća kako analizu i kreiranje korisničkog iskustva u poznatoj zoni, odnosno kroz utabane analitičke staze, tako i ono neotkriveno, što donosi brojne mogućnosti, otkriva nove potencijale i razvija marketinške inovacije.

Influencer marketing se stoga, osim *per se*, treba sagledavati i holistički - ne samo kroz kreiranje korisničkog iskustva i povezivanje s brendom, što je danas primarni cilj djelovanja influencera, već treba ići i korak dalje. Influencer marketing treba postati integralnim dijelom današnje šire perspektive digitalnog marketinga koji, s jedne strane, treba biti bliskiji, prisniji i čovječniji, što je vjerojatno najpoželjnija 'marketinška vrlina' influencera, dok s druge strane marketing treba u najvećoj mjeri koristiti domete novih tehnologija, pri čemu je umjetna inteligencija alat i/ili nova marketinška realnost koja nadilazi sadašnju moć predviđanja.

Svakako, pred digitalnim marketingom pojavljuju se novi izazovi. Promjena načina razmišljanja, pri čemu je dizajnersko razmišljanje jedno od vodećih koncepata, nudi tek jednu od nužnih pretpostavki ukoliko se želi 'dohvatiti' nova, ili tzv. Z potrošačka generacija. U konačnici, cijeli taj proces treba biti održiv, i ne smije, u 'nepodnošljivoj lakoći (digitalne) komunikacije', izgubiti svoju ljudsku komponentu. Jer u konačnici, marketing jest, i treba ostati, aktivnost 'čovjeka čovjeku'. Pa makar i *persone* influencera nepoznatom korisniku na društvenim mrežama. Treba se povremeno prisjetiti da su ishodišta marketinga 'štandovi' na istočnjačkim bazarima, ali i domaćim tržnicama i tržnicama svugdje u svijetu, koje su jedne od vodećih turističkih atrakcija u svakom gradu, a da je kupnja na njima ne samo ekonomska transakcija već i jedinstveno socijalno, ali i osobno, autentično, i često nezaboravno iskustvo. Stoga, u bespućima eksponencijalno ubrzanog razvoja digitalne stvarnosti i novih tehnologija marketing mora sačuvati svoje ishodište, autentičnost i ljudskost. To je održivi marketing kojemu težimo, a da se pritom što učinkovitije ostvaruju marketinški ciljevi. Ovo postavlja velike izazove za buduća istraživanja u marketingu i marketinškoj praksi, ali se s njima valja suočiti u uzbudljivom traganju za marketingom budućnosti.

REFERENCE

[1] De Veirman, M., Hudders, L., & Nelson, M. R. (2019). What is influencer marketing and how does it target children? A review and direction for future research. Frontiers in psychology, 10, 2019.

[2] Enke, N., & Borchers, N. S. (2019). Social media influencers in strategic communication: A conceptual framework for strategic social media influencer communication. International journal of strategic communication, 13(4), str. 261-277, 2019.

[3] Ewers, N. L. (2017). #sponsored–Influencer Marketing on Instagram: An Analysis of the Effects of Sponsorship Disclosure, Product Placement, Type of Influencer and their Interplay on Consumer Responses. Master's thesis, University of Twente.

[4] Geyser, W. (2022). Influencer MarketingHub. What is an Influencer? – Social Media Influencers Defined, https://influencermarketinghub.com/what-is-an-influencer/, preuzeto: [28.kolovoz 2022]

[5] Geyser, W. (2022). Influencer MarketingHub. Why Your Brands Needs User-Generated Content on TikTok, https://influencermarketinghub.com/user-generated-content-tiktok/, preuzeto: [25. kolovoz 2022]

[6] Geyser, W. (2022), Influencer MarketingHub. What is Influencer Marketing? – The Ultimate Guide for 2022., https://influencermarketinghub.com/influencer-marketing/, preuzeto: [25. kolovoz 2022]

[7] Haenlein, M., Anadol, E., Farnsworth, T., Hugo, H., Hunichen, J., & Welte, D. (2020). Navigating the New Era of Influencer Marketing: How to be Successful on Instagram, TikTok, & Co. California management review, 63(1), str. 5-25, 2020.

[8] Isosuo, H. (2016). Social media influencer marketing. Bachelor's Thesis, JAMK University of Applied Sciences.

[9] Lemon, K. N., & Verhoef, P. C. (2016). Understanding customer experience throughout the customer journey. Journal of marketing, 80(6), str. 69-96, 2016.

[10] Magic, J. & Helmstetter A., (2023). Convince&convert. Great Customer Experience Starts with Great Employee Experience, https://www.convinceandconvert.com/customer-experience/great-cx-starts-with-great-employee-experience/, preuzeto: [27. travnja 2023]

[11] Ojurović Čačić, M. (2022). Influencer marketing (diplomski rad). Sveučilište u Zadru, Zadar.

[12] Reinecke, S. (2016). What is it that design thinking and marketing management can learn from each other?. In: Brenner, W., Uebernickel, F. (eds) Design Thinking for Innovation. Springer, Cham.

[13] Saleh, K. (2023). Zaytech. Integrated Customer Experience, https://zaytech.com/blog/integrated-customer-experience/, preuzeto: [27. travanj 2023]

[14] Sammis, K., Lincoln, C., Pomponi, S. (2015). Influencer marketing for dummies. For dummies, A Wiley Brand.

[15] Schiele, K., & Chen, S. (2018). Design thinking and digital marketing skills in marketing education: A module on building mobile applications. Marketing Education Review, 28(3), str. 150-154, 2018.

[16] Segova, A. (2020). Consumer responses to influencer marketing on Instagram. Doctoral dissertation, University of Technology Sydney. School of Communication.

[17] Simonova, Lj. (2021). Influencer MarketingHub. 12 Common Influencer Marketing Mistakes, https://influencermarketinghub.com/influencer-marketing-mistakes/, preuzeto: [26. kolovoz 2022]

[18] Total digital, (2023). Design thinking - User-centric design for websites and applications that deliver results, https://www.totaldigital.ie/design-thinking/4, preuzeto: [27. travanj 2023]
[19] Vasilieva, E. V. (2018). Design-thinking: practice of customer experience research. Современные информационные технологии и ИТ-образование, 14(2), str. 325-332, 2018.
[20] Weiland, K. J., & Knizhnik, J. R. (2022). Design thinking, lean startup, and high-technology marketing for human-centered systems engineering. Systems Engineering, 25(3), str. 207-223, 2022.
[21] Zaytech, (2023). Integrated Customer Experience, https://zaytech.com/blog/integrated-customer-experience/, [pristupljeno: 27. travanj 2023.]

Original scientific paper / Izvorni znanstveni rad

RESEARCH OF THE INFLUENCE OF QUALITY PERCEPTION, CUSTOMER SATISFACTION AND BRAND IMAGE ON SPORTS FOOTWEAR BRAND LOYALTY

DAMIR DOBRINIĆ
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
ddobrinic@foi.hr

ABSTRACT

This paper aims to investigate the relationship between brand image, customer satisfaction, and perceived brand quality with brand loyalty and the relationship between perceived brand quality and brand image. Based on the literature analysis, a conceptual research model was created and hypotheses were proposed. To test the model and hypotheses, the structural equation modeling method (SEM) was used with the help of the SPSS AMOS 26 software package. For the purpose of data collection, a survey was conducted via the Facebook social network, and 201 correctly filled questionnaires were collected. The research results show: A) a positive association between brand image and brand loyalty, B) a positive association between perceived quality and brand image, and C) a positive association between brand image and customer satisfaction. A positive relationship between customer satisfaction and brand loyalty and between perceived quality and brand loyalty has not been established. The results of the research help in understanding the process of forming customer loyalty of sports footwear brands.

KEYWORDS: brands image, loyalty, customer satisfaction, perceived quality

1. INTRODUCTION

A simple definition defines a brand as a type of product manufactured by a specific company under a specific name. Selected elements of the brand (name, symbol, slogan, color...) determine the product and give it an identity that sets it apart from the multitude of the same or similar products. A more complete definition is given by Kotler and Armstrong [2018], stating that a brand is much more than just a name and a symbol, it represents the perception and feelings that customers have about the product and its performance, in this regard they emphasize that "products are created in a factory, and brand in the minds of consumers". Along these lines, the Economic Times [20/7/2023] states that brands are similar to living beings, they have their own identity and personality, their own culture, vision, emotion, and intelligence. What many definitions agree on is that a brand creates loyalty, trust, and attraction, three essential elements that set it apart and make it special. The goal of marketing is to instil or position this uniqueness in the consumer's mind. The goal of marketing is to instil or position this uniqueness in the consumer's mind. In the context of brand positioning, this paper

investigates the interrelationship of four factors (variables): brand image, perceived brand quality, brand loyalty, and customer satisfaction. The paper consists of five parts, after the introductory part, the review of the literature and the formation of hypotheses, the methodology is explained and the results of the research are analysed. The final part of the paper refers to the discussion, implications, and limitations of the research and presentation of the literature used.

2. LITERATURE REVIEW

Along with the concept of a brand and its meaning for both the company and consumers, there is also the concept of loyalty, which Nedović & Čabarkapa [2010] describes as the consumer's determination to buy the same brand continuously . Since the goal of the company and the brand is to have as long a life as possible, achieving the loyalty of its customers becomes the "condition sine qua non" of successful business and survival on the market. The repeat purchase ensured by loyalty strengthens the competitiveness of the brand and its further development.

Kotler and Armstrong [2018] put brand loyalty in a direct relationship with customer satisfaction. A satisfied customer not only buys again, but also conveys his satisfaction to others. The goal of the brand is to provide those values that will achieve and strengthen customer satisfaction, and thus loyalty to the brand. A factor that greatly impacts satisfaction and loyalty, and the brand's overall reputation or image, is its quality. By its very existence, a brand communicates a certain quality and is a guarantor of that quality. The task of marketing is to make that quality visible and implant it in the consumer's consciousness, and the literature often talks about perceived quality, which Zeithaml [1988] defines as the consumer's judgment of the overall excellence or superiority of the product.

Brand image, perception of brand quality, customer satisfaction, and brand loyalty are factors whose mutual relationship has been established through various research [Ghulam & Imran, 2020], [Mabkhot et al., 2017], [Neupane, 2015]. In this research, the model developed in their research by Ghulam & Imran, [2020] was tested. Based on the literature review, the conceptual research model [Figure 1] and proposed hypotheses were defined.

Figure 1. Conceptual research model

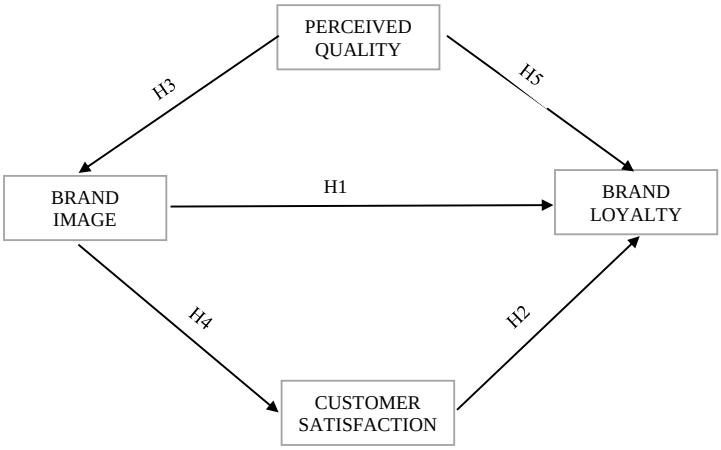

2.1. BRAND IMAGE AND BRAND LOYALTY

According to Drucker et al. [2008], there is only one valid definition of business purpose – creating customers. In this, the task of marketing is to create a brand that will be desirable and thereby make sales redundant. Lee et al. [2014], in the context of different definitions and measurements, define the brand image as the sum of customer perceptions of the brand generated by the interaction of cognitive, affective, and evolutionary processes in the customer's mind.

Along these lines, Zhang [2015] also considers the brand image as a key driver of brand value, which refers to the consumer's general perception and feeling about the brand and has an impact on their behaviour. Various studies investigate the connection between brand image and brand loyalty [Abdullah, 2015], [Ghulam, & Imran, 2020], [Puška et al.]. Based on previous research, hypothesis H1 was proposed.

H1: Brand image is positively related to brand loyalty.

2.2. CUSTOMER SATISFACTION AND BRAND LOYALTY

Algesheimer et al. [2005] point out that customer loyalty is their willingness to buy products from a particular supplier and to commit to that supplier in the long term despite the potential benefits of switching suppliers. Kotler and Keller [2016] talk about "the deep commitment of a customer to buy a product or service from a particular company again in the future even if there are factors that can cause a behaviour change". On the other hand, customer satisfaction with a brand is the result of a subjective assessment that the selected brand meets or exceeds customer expectations [Syarifah and Muhti, 2020]. Various researches determined the connection between customer satisfaction and brand loyalty [Syarifah & Mukti, 2020], [Ghulam & Imran, 2020], [Mahmood et al., 2018], [Gautam, 2019]. Based on previous research, hypothesis H2 was formed.

H2: Customer satisfaction is positively related to brand loyalty.

2.3. PERCEIVED QUALITY AND BRAND IMAGE

Product quality is the basis of building a brand and is its guarantor. Quality and the guarantee of that quality to the brand, as stated by Aaker [1991], gives the possibility of differentiation from the competition, charging a higher price and the basis for further expansion, while customers get a good reason to buy and fulfil their expectations. Vidović [2018], in this context, emphasizes the role of quality in reducing the risk of a purchase. Therefore, it is important to view quality not only as technical performance (few failures, remarks, etc.) but as "the customer's perception of the superiority of the product or service concerning their purpose, compared to alternatives" [Zeithaml, 1988]. The positive association of perceived quality with a brand image is confirmed by various studies [Ghulam & Imran, 2020], [Alhaddad, 2015] [Vinh & Phuong, 2017]. In accordance with previous research, hypothesis H3 was proposed.

H3: Perceived brand quality is positively related to brand image.

2.4. BRAND IMAGE AND CUSTOMER SATISFACTION

More research establishes a positive relationship between brand image and customer satisfaction [Nugroho et al. 2021], [Ghulam & Imran, 2020], [Coung, 2020], [Mohammed & Rashid, 2018], however, some research finds this positive they do not find a connection

[Syaifuddin et al., 2022]. In connection with building a strong image, brand personality and its influence on customer satisfaction are also connected, given that individuals use this personality to build and emphasize their personality [Su & Tong, 2016]. In accordance with previous research, hypothesis H4 was proposed.

H4: Brand image is positively related to customer satisfaction.

2.5. PERCEIVED QUALITY AND BRAND LOYALTY

Civelek & Ertemel, [2019] state that quality perception can be defined as "the consumer's overall assessment of the risks and rewards associated with a particular brand and its products". The influence of perceived brand quality on customer loyalty is confirmed by various studies [Akoglu, Ozbek, 2022], [Ghulam, 2020], [Falahat et al., 2018], [Saleem et al., 2015], [Pappu et al., 2005]. In accordance with previous research, hypothesis H5 was proposed.

H5: Perceived brand quality is positively related to brand loyalty.

3. RESEARCH METHODOLOGY

3.1. SCALE DEVELOPMENT

Following the proposed conceptual model, the paper determined the connection between brand image, customer satisfaction, and perceived brand quality with brand loyalty, and the connection between perceived brand quality and brand image. The measurement scale developed by Ghulam and Imarn (2020) was used in the research. The questionnaire consisted of a total of 25 questions, of which 4 questions were general, while the rest represented statements where respondents determined their degree of (dis)agreement or disagreement through a five-point Likert scale. (1=do not agree at all, 5=completely agree). [Table 1] Respondents tied their answers to the brand of sports shoes that they indicated they preferred.

Table 1. Original measurement items

Construct	**Measurement items**	
Brand image	BI1	I think that this brand is friendly
	BI2	I think that this brand is modern.
	BI3	I think that this brand is popular.
	BI4	I think that this brand is useful.
	BI5	I think that this brand is gentle. *****
	BI6	1 think that this brand is artificial**. ***
Brand loyalty	BL1	Brand loyalty creates commitment in the mind of consumers.
	BL2	Pricing strategies of the brand make the consumer more loyal to it.
	BL3	Proper communication between the brand and consumers promotes loyalty.
	BL4	Positive WOM generated by the consumers enhances brand loyalty.
	BL5	Firms with strong loyal customers have to spend fewer resources on marketing. *
Perceive quality	PQ1	X is of high quality.
	PQ2	The likely quality of X is exceptionally high.
	PQ3	The likelihood that X would be functional is very

		high.
	PQ4	The likelihood that X is reliable is very high.
	PQ5	X must be of outstanding quality.
Customer satisfaction	CS1	X brand makes me feel delighted.
	CS2	X brand gives me pleasure.
	CS3	X brand Increases my frequency of use.
	CS4	X brand makes me feel good.
	CS5	X brand prevents me from looking cheap and another brand. *

* Due to the low factor loading, questions BI5, BI6, BL5 and CS5 were omitted from further analysis.

3.2. DATA COLLECTION AND PARTICIPANTS

Empirical research was conducted with the help of a questionnaire created through Google Forms and distributed through the social network Facebook. The research took place in the period from May 15, 2023, to July 4, 2023, and 201 correctly completed questionnaires were collected. According to the demographic indicators, 45 (22.4%) men and 156 (77.6%) women participated in the research. Most respondents are in the age group between 18-25 years, 112 of them (55.7%), while in the group of 26-40 years, there are 75 of them (37.3%), in the group of 41-54 there are 9 of them (4.5%), in the group of 55 and over 4 (2%). There is only 1 respondent (0.5%) in the group under 18 years of age. According to work status, the majority of respondents have the status of employees, 95 (47.3%), while 93 (46.3%) are students. There are 10 (5%) unemployed respondents, 2 (1%) students, and 1 (0.5%) pensioner.

4. DATA ANALYSIS

4.1. EXPLORATORY FACTOR ANALYSIS (EFA) AND RELIABILITY

The validity of the measuring instrument was determined by checking its construct, content, convergent, and discriminant validity. Construct and content validity was established by applying a theory-tested measuring instrument and by conducting exploratory factor analysis (EFA), which confirmed the preset factor structure. The consistency of data for conducting EFA was determined by Bartlett's test of sphericity and the Kaiser-Mayer-Olkin test of sampling adequacy (KMO). Factor analysis was performed with the help of the IBM SPS 23 statistical software package [Table 2].

Table 2. KMO and Bartletts test

Kaiser-Meyer-Olkin test of sampling adequacy	,850
Bartlett's Test of sphericity, χ^2	2151,376
Degrees of freedom (df)	171
Significance (Sig)	,000

The Kaiser-Mayer-Olkin sampling adequacy test is greater than the reference limit of 0.6, while Bartlett's sphericity test is high ($\chi 2 = 2151.376$) and significant with a risk of less than 1% (Šram, 2014). The obtained results indicate the appropriateness of the implementation of the EFA analysis, which was carried out on 21 items of the measuring instrument. During the analysis, 4 items (BI5, BI6, BL5, and CS5) were excluded from further analysis due to low factor loading. Principal components analysis with varimax rotation (respecting the Kaiser-

Guttman criterion - each factor has eigenvalues greater than 1) identified 4 factors with factor loading greater than 0.5, explaining 65.410% of the total variance.
The internal consistency or reliability of the measuring instrument was measured by determining the Cronbach alpha coefficient, the value of which can range between 0 and 1, the closer the value is to 1, the more reliable the measuring instrument is. The determined values range between 0.758 and 0.922, coefficient values between 0.6 and 0.7 are considered acceptable, while values above 0.7 are desirable [Schmitt, 1996].

Convergent validity, with the purpose of checking the connection within the construct, was measured using the average extracted variance (AVE) whose value for an individual construct must be 0.5 or more [Ahmed et al., 2016], and using the composite reliability coefficient (CR) whose the value should be greater than 0.6 [Fornely & Larcker, 1981].

The results shown in Table 3 indicate that the reference criteria for determining the validity and reliability of the measuring instrument are met.

Table 3. Internal reliability and convergent validity

		Internal reliability			Convergent validity			
Construct	Item	Cronbach`s alpha)	Item- total correlation	Factor loading	Composite reliability	AVE	Mean	SD
Brand image	BI1		,469	,529			4,378	0,5969
	BI2	,758	,722	,896	,782	**,49***	4,535	0,5830
	BI3		,554	,506			4,637	0,5408
	BI4		,492	,783			1,259	0,5854
Brand loyalty	BL1		,600	,632			3,985	1,0123
	BL2	,796	,544	,533	,794	,50	3,930	0,9084
	BL3		,712	,903			4,229	0,8760
	BL4		,587	,709			4,308	0,8452
Perceived quality	PQ1		,795	,812			4,025	0,8743
	PQ2	,922	,834	,825	,918	,69	3,940	0,9146
	PQ3		,720	,745			4,164	0,7602
	PQ4		,803	,859			4,080	0,8328
	PQ5		,838	,910			3,766	0,9056
Customer satisfaction	CS1		,799	,886			3,896	1,0218
	CS2	,890	,783	,862	,892	,68	4,147	0,8450
	CS3		,711	,747			4,055	0,9284
	CS4		,755	,786			4,070	0,9824

* A slight deviation from the reference limit of 0.50 with respect to other indicators can be tolerated [Fornell, Larcker, 1981].

In order to confirm that the variables within a certain factor do not correlate strongly with the variables in another factor, the discriminant validity of the measuring instrument was tested with the help of the statistical program package IBM SPSS AMOS 26. It was determined that the square of the AVE value of each construct is greater than the correlation of that construct and either of any other construct [Kitchenham, Charters, 2007]. The result in Table 4 confirms good discriminant validity.

Table 4. Discriminant Validity

	BI	BL	PQ	CS
BI	**0,700**			
BL	0,348	**0,707**		
PQ	0,469	0,247	**0,832**	
CS	0,486	0,291	0,486	**0,822**

4.2. MODEL VERIFICATION USING STRUCTURAL EQUATION MODELING (SEM)

To check the adequacy of the proposed model and test the hypotheses, the structural equation method (SEM) was used with the help of the SPSS AMOS 26 statistical software package. As a rule, the following fit indices are most often used: relative chi-square test and its correction with respect to the number of degrees of freedom (x2/df), GFI - goodness of fit index, NFI - normalized fit index, TLI - Tucker-Lewis index, CFI - comparative fit index, RMSEA - root mean square error of approximation, and SRMR - standardized root mean square residual. The results obtained after the implementation of the SEM analysis show a good agreement between the proposed model and the obtained real data. [Table 5] A graphic representation of the structural model and connections between factors is shown in Figure 2.

Table 5. Fit indices

Fit indices	Test model	Recommended value	Source
Chi-square	197,746; df=104, p<0,001		
χ^2/df	1,904	< 5	Park & Kim, (2014)
GFI	0,893	>0,8	Halmi, (2016)
NFI	0,906	>0,9	Halmi (2016)
IFI	0,953	>0,9	Park & Kim, (2014)
TLI	0,938	>0,9	Kim & Han, (2014)
CFI	0,952	>0,9	Hu & Bentler, (1999)
RMSEA	0,067	0,03 to 0,08	Hair et al., (2014)
SRMR	0,063	<0,08	Hair et al., (2014)

Figure 2. Structural model – path analyse

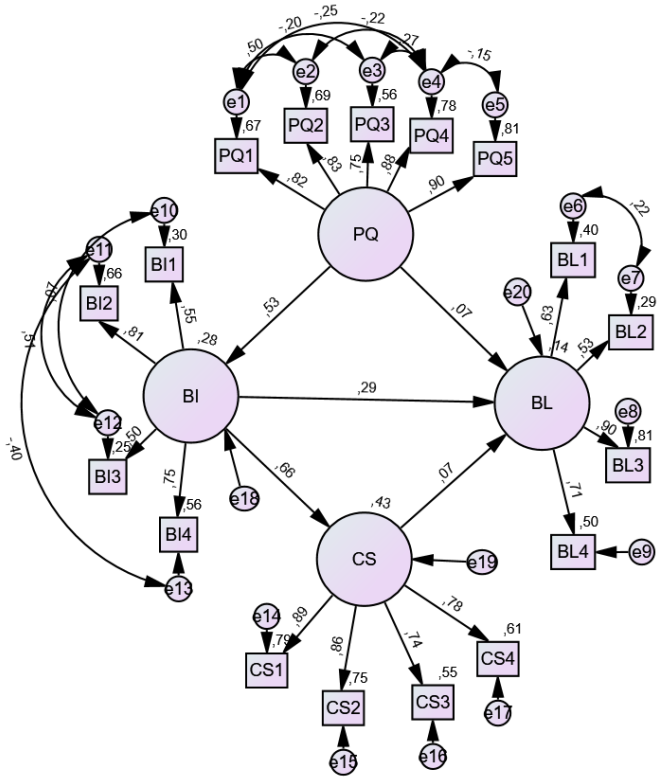

4.3. HYPOTHESIS TESTS

The proposed hypotheses were tested using the method of structural equation modeling (SEM). The test results are shown in Table 6 and Figure 3. According to the results, hypothesis H1 is confirmed, there is a positive relationship between brand image and brand loyalty (ß = 0.287, CR = 2.110, p <0.05). Hypothesis H2 was not confirmed, and a positive relationship between customer satisfaction and brand loyalty was not established (ß = 0.072, CR = 0.643, p >0.05). Hypothesis H3 is confirmed, there is a positive relationship between perceived quality and brand image (ß = 0.531, CR = 5.250, p <0.001). Hypothesis H4 was confirmed, there is a positive relationship between brand image and customer satisfaction (ß = 0.657, CR = 6.233, p <0.001). Hypothesis H5 was not confirmed, and a positive relationship between perceived brand quality and brand loyalty was not established (ß = 0.067, CR = 0.718, p >0.05).

Table 6. Results of hypothesis testing

Hypothesis	Independent variable	Dependent variable	Standard estimate	CR	P-value	Supported
H1 (+)	BI	BL	0,287	2,110	0,035	Supported
H2 (+)	CS	BL	0,072	0,643	0,520	N/S
H3 (+)	PQ	BI	0,531	5,250	***	Suported
H4 (+)	BI	CS	0,657	6,233	***	Suported
H5 (+)	PQ	BL	0,067	0,718	0,472	N/S

Figure 3. Results of hypothesis testing

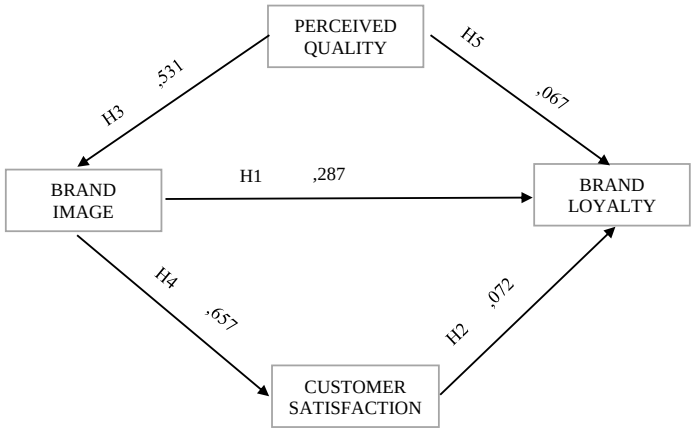

By implementing the structural equation modeling method, the coefficient of determination (R2) was measured, the value of which can range between 0 and 1. The model is more representative if the value is closer to 1. The result shows that 0.143% of the variance of the dependent variable brand loyalty is explained by three independent variables (perception of quality, brand image, and customer satisfaction), 0.282% of the variance of the dependent variable brand image is explained by one independent variable (perception of quality), and 0.432% of the variance of the dependent variable customer satisfaction is explained by the independent variable brand image. [Table 7]

Table 7. Squared multiple correlation of the proposed research model

Construct	Values %
Brand loyalty (BL)	14,30 (0,143)
Brand image (BI)	28,20 (0,282
Customer satisfaction (CS)	43,20 (0,432)

5. RESULT AND DISCUSSION

Within the defined goal of this research, the connection between brand image, customer satisfaction, and perceived brand quality with brand loyalty and the connection between perceived brand quality and brand image was determined.

The positive association of the brand image with brand loyalty was established and hypothesis H1 was confirmed. The result is in line with previous research [Abdullah, 2015], [Puška et al.], where the claim of Išoraitė [2018] is confirmed that a strong brand creates trust among customers, while trust encourages loyalty.

Unexpectedly, hypothesis H2 "Customer satisfaction is positively related to brand loyalty" was not confirmed. The association was not established, which is contrary to various previous research in different industrial fields [Ghulam, and Imran, 2020], [Syarifah & Mukti, 2020], [Mahmood et al., 2018], [AL-Msallam, 2015] where this connection is significant. This research focused on the sports footwear industry, and the result can be indicative in terms of customer retention and loyalty. Loyalty requires a constant examination of the value obtained by purchasing a particular brand. The obtained result certainly requires verification through further research on different samples of respondents.

A significant relationship (ß = 0.531) between perceived quality and brand image was confirmed (H3), which is consistent with earlier research [Ghulam & Imran, 2020], [Alhaddad, 2015], [Vinh & Phuong, 2017], [Ranjbarian et al., 2012]. According to the obtained results, it can be concluded that customers with a high perceived quality of a certain brand will choose a product with a good image [Setyawan et al., 2020].

Hypothesis H4, which assumed a connection between brand image and customer satisfaction, was confirmed, the connection exists and is very significant (ß = 0.657). The result is in accordance with previous research, [Nugroho et al. 2021], [Ghulam and Imran, 2020], [Coung, 2020], [Mohammed & Rashid, 2018]. The result indicates that the brand image of sports footwear affects customer satisfaction. The image represents the perception of a brand based on associations stored in customers' memories. If these associations are in line with customer expectations, they will positively influence their purchase decisions [Coung, 2020].

Unexpectedly, hypothesis H5 was not confirmed, there is no connection between the perception of brand quality of sports shoes and brand loyalty. The result is contrary to the results of previous research that emphasize the importance of perceived quality in building loyalty and the necessity that it is in line with real quality [Akoglu & Ozbek, 2022], [Ghulam & Imran, 2020], [Saleem et al., 2015]. The result can be indicative given that the respondents are mostly members of Generation Z (55.7%) and millennials (37.3%), who have their own specifics and certain value attitudes [Hassan & Rasel, 2018]. The result certainly requires additional verification through future research.

6. IMPLICATIONS AND LIMITATIONS OF RESEARCH

The primary goal of this paper is to determine the connection between the brand image of sports shoes and customer loyalty. In addition, the relationship between perceived brand quality and customer satisfaction with image and loyalty was investigated. The results of the research confirmed the positive association o brand image with brand loyalty and the positive association

of quality perception with image and image with customer satisfaction. A positive relationship between customer satisfaction and brand loyalty and a positive relationship between quality perception and brand loyalty has not been established.

The theoretical contribution of this research is reflected in the findings that support the authenticity of previous research models on the importance of the relationship between brand image and brand loyalty. The results of the research help in understanding the process of forming customer loyalty of sports footwear brands. The theoretical model requires constant verification, given that consumer behaviour constantly changes. This is indicated by the results of the research, especially the non-confirmation of hypotheses H2 and H2.

The research can also be helpful to practitioners who indicate the connection of key factors in customer behaviour that lead to repeat purchases and a longer customer retention time (their longer lifecycle), which ensures their competitiveness and longer survival on the market. These insights should be the backbone of their marketing plans, which will be directed towards improving the image of their brands, a positive image leads to greater satisfaction and desirable customer loyalty.

The research also has its limitations, primarily reflected in the size and structure of the sample of respondents and the use of one social network to distribute the survey questionnaire. Future research would be useful to target different generations of customers and investigate their perceptions of the quality and image of brands and the criteria for acquiring their loyalty.

REFERENCES

[1] Aaker, D.A. (1991), *Managing Brand Equity: Capitalizing on the Value of a Brand Name*, New York: The Free Press p. 54

[2] Abdullah, A., (2015.) Perceived Quality, Brand Image and Brand Trust as Determinants of Brand Loyalty, *Journal of Research in Business and Management* Volume 4(2015) pp. 01-08

[3] Ahmad , S., Zulkurnain, N., & Khairushalimi, F. (2016). Assessing the Validity and Reliability of a Measurement Model in Structural Equation Modeling (SEM). *British Journal of Mathematics and Computer Science*, pp. 1-8

[4] Akoglu, H.E., Ozbek, O., (2022), The effect of brand experiences on brand loyalty through perceived quality and brand trust: a study on sports consumers, *Asia Pacific Journal of Marketing and Logistics* Vol. 34 (10), pp. 2130-2148

[5] Algesheimer, R. & Dholakia, M. (2005), The Social Influence of Brand Community: Evidence from European Car Clubs, Journal of Marketing 69(4), pp. 19-34

[6] Alhaddad, A. (2015). A structural model of the relationships between brand image, brand trust, and brand loyalty. *International Journal of Management Research and Reviews*, 5(3), pp. 137-144

[7] AL-Msallam, S., (2015), The Relationship between Customer Satisfaction and Customer Loyalty in the Banking Sector in Syria, *Journal of Marketing and Consumer Research*, Vol.7, pp. 27.-34

[8] Bagozzi, R. P., Yi, Y. (1988), On the evaluation of structural equation models. *Journal of the Academy of Marketing Science*, 16(1); pp. 74-94

[9] Bilgin, Yusuf. (2018). The effect of social media marketing activities on brand awareness, brand image, and brand loyalty. *Business & Management Studies: An International Journal*. Vol. 6 (1), pp. 128-148

[10] Chao, R. F., Wu, T. C. & Yen, W. T. (2015). The Influence of Service Quality, Brand Image, and Customer Satisfaction on Customer Loyalty for Private Karaoke Rooms in Taiwan. The Journal of Global Business Management, 11(1), pp. 59-67
[11] Chinomona, R. (2016). Brand communication, brand image, and brand trust as antecedents of brand loyalty in Gauteng Province of South Africa. African Journal of Economic and Management Studies, 7(1), pp. 124-139
[12] Civelek, M. E., Ertemel, A. V., (2019). The role of brand equity and perceived value for stimulating purchase intention in b2c e-commerce websites, Business and Economics Research Journal, 10(1), pp. 233-243
[13] Coung, D.T. (2020.). The Impact of Customer Satisfaction, Brand Image on Brand Love and Brand Loyalty, *Journal of Adv Research in Dynamical & Control Systems*, Vol. 12(6), pp. 3151-3159
[14] Drucker, Peter F. and J. A. Maciariello (2008), *Management: Revised Edition*, New York: Harper Collins, p. 30.
[15] Falahat, M., Shyue Chuan, C. i Bik Kai, S. (2018). Brand Loyalty and Determinates of Perceived Quality and Willingness to Order., *Academy of Strategic Management Journal,* Vol.17(4)
[16] Fornell, Fornell, C. and Larcker, D.F. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error, *Journal of Marketing Research*, 18, pp. 39-50
[17] Fotova Čiković, K. (2021). Utjecaj čimbenika poznatost marke, percepcija kvalitete i aktivnosti digitalnog marketinga na tržišnu vrijednost marke na primjeru hrvatskog poduzeća Kateme. *Zbornik radova Ekonomskog fakulteta Sveučilišta u Mostaru*, (27), pp. 25-51
[18] Gautam, V. (2019.), Predictors of Customer Loyalty: A Case of Indian Mobile Telecommunication Services Sector, *Academy of Marketing Studies Journal,* Vol 23(4), pp. 1-18
[19] Ghulam, M. i Imran, T. (lipanj 2020). Brand Loyalty and the Mediating Roles of Brand Image and Customer Satisfaction, *Market College of Management Sciences*, Vol. 15(1). pp. 101-119
[20] Hair, Jr. F. J., Black, R. E., Babin, J. B. & Anderson, E. R. (2014). *Multivariate Data Analysis* (7th ed.). Harlow, Pearson Education Limited, pp.579
[21] Halmi, A. (2016). *Multivarijantna analiza u društvenim znanostima*. Zagreb, Alineja d.o.o., pp.175.
[22] Hassan, M., Rasel, K.A. (2018). Determinants of Brand Loyalty of Millennial or Generation Y, *Barishal University Journal* Part III, Volume 5 (1), pp. 97-108
[23] Hu, L. & Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. Structural Equation Modelling: A Multidisciplinary Journal, 6(1), pp. 1-55
[24] Išoraitė, M. (2018). Brand Image Theoretical Aspects. Integrated Journal of Business and Economics. 2(1), pp. 116 -122
[25] Keller, K. L. (2009). Building strong brands in a modern marketing communications environment. *Journal of Marketing Communications*, 15(2/3), pp. 139-155
[26] Kitchenham B., Charters, S. (2007.) Guidelines for performing Systematic Literature reviews in Software Engineering Version 2.3, *Engineering*, Vol. 45, no. 4,, p. 1051
[27] Kim, Y. and Han, J. (2014). Why Smartphone Advertising Attracts Customers: A Model of Web Advertising, Flow, and Personalization. *Computers in Human Behavior*, 33, pp. 256-269
[28] Kotler P. & Keller, K. L. (2016). *Marketing management* (15thed). Pearson Education, Inc. str. 68.

[29] Kotler, P., Armstrong, G.(2018), *Principles of Marketing*, Pearson, p. 264
[30] Krupka, Z. i Škvorc, A. (2014). Važnost identiteta snažne marke u stvaranju lojalnosti i povjerenja potrošača. Zbornik Ekonomskog fakulteta u Zagrebu, 12 (1), pp. 113-125
[31] Lam, L.W. (2012). Impact of competitiveness on salespeople's commitment and performance, *Journal of Business Research*, 65(9), pp. 1328-1334
[32] Lee, J. & James, Jeffrey & Kim, Yu. (2014). A Reconceptualization of Brand Image. International, Journal of Business Administration, Vol. 5(4),
[33] Mabkhot, H. A., Shaari, H. & Salleh, S. M. (2017). The influence of brand image and brand personality on brand loyalty, mediating by brand trust: An empirical study, *Journal Pengurusan (UKM Journal of Management*), 50, pp. 71-82
[34] Mahmood, Atif, Lugman, M., Tauheed, Rana, Kanwal, Sara (2018). Relationship between Service Quality, Customer Loyalty and Customer Satisfaction *The Lahore Journal of Business* 6 (2), pp. 135–154
[35] Mohammed, A. & Rashid, B. (2018). A conceptual model of corporate social responsibility dimensions, brand image, and customer satisfaction in the Malaysian hotel industry. *Kasetsart Journal of Social Sciences*, 39(2), pp. 358-364
[36] Nedović Čabarkapa, M. (2010). Stvaranje konkurentske prednosti gospodarskog subjekta kroz izgradnju robne marke. *Ekonomski vjesnik*, XXIII (1), 274-281.
[37] Neupane, R. (2015). The effects of brand image on customer satisfaction and loyalty intention in the retail supermarket chain, UK. *International Journal of Social Sciences and Management, 2(1), pp.* 9-26
[38] Nugroho M. W., Woro U., Yuyun W., Andi I., Rusdiyanto, Nawang K. (2021). The Impact of Price, Brand Image and Quality of Service on Consumer Loyalty through Consumer Satisfaction Delivery Services, *Journal of Legal, Ethical and Regulatory Issues*, Vol: 24 Issue: 6S
[39] Pappu, R., Quester. P.G., & Cooksey, R.W. (2005). Consumer-based-brand equity: Improving the measurement empirical evidence. *Journal of Product & Brand Management*, 14(3), pp. 143-154
[40] Park, E., Kim, K. J., (2014). An Integrated Adoption Model of Mobile Cloud Services: Exploration of Key Determinants and Extension of Technology Acceptance Model. *Telematics and Informatics*, 31, pp. 376-366
[41] Puška, A., Stojanović, I. & Berbić, S. (2018). The impact of chocolate brand image, satisfaction, and value on brand loyalty, *Economy & Market Communication Review/Casopis za Ekonomiju i Trzišne Komunikacije,* 8(1*), pp.* 37-54
[42] Rajh E. (2009). Razvoj mjernih ljestvica za mjerenje specifičnih elemenata marketinškog miksa usluga. *Ekonomski vjesnik: Review of Contemporary Entrepreneurship, Business, and Economic* Issues, 22(2), pp. 340-350
[43] Ranjbarian, B., Sanayei, A., Rashid, M., Hadadian, A.(2012). An Analysis of Brand Image, Perceived Quality, Customer Satisfaction and Re-purchase Intention in Iranian Department Stores, *International Journal of Business and Management*. Vol. 7, No. 6. pp. 40-49
[44] Saleem, S., Rahman, S. U. & Umar, R. M. (2015). Measuring customer-based beverage brand equity: Investigating the relationship between perceived quality, brand awareness, brand image, and brand loyalty. *International Journal of Marketing Studies*, 7(1), p. 66
[45] Saleem, S., Rahman, S. U. & Umar, R. M. (2015). Measuring customer-based beverage brand equity: Investigating the relationship between perceived quality, brand awareness, brand image, and brand loyalty. *International Journal of Marketing Studies, 7(1)*, p. 66.
[46] Schmitt, N., (1996). Uses and abuses of coefficient alpha, *Psychological Assessment*, 8(4), pp. 350–353

[47] SeKhaton F.S., Mugiono, Hussein, A.S. (2020.). The effect between brand awareness, perceived quality, and brand loyalty through a brand image (study on pt. east west seed Indonesia charge brand cap brick seed products, banyuwangi), *International Journal of Business, Economics, and Law,* Vol. 23(1), pp. 216.-224

[48] Su, J., Tong, X. (2016). Brand Personality, Consumer Satisfaction, and Loyalty: A Perspective from Denim Jeans Brands. *Family and Consumer Sciences Research Journal,* 44(4), pp. 427–446

[49] Syaifuddin, Yuswanto, A., Hariri, A. (2022). The Influence of Brand Image, Awareness, and Customer Satisfaction in Increasing Loaylity And Choosing Islamic Banking In Indonesia, *East Asian Journal of Multidisciplinary Research,* Vol. 1(4)

[50] Syarifah, A, Mukti, M.A (2020.). Influence Analysis of Product Quality and Brand Trust against Customer Satisfaction and Impact on Customer Loyalty Wardah Brand Cosmetics in Jabotabek, *International Journal of Innovative Science and Research Technology,* Volume 5, Issue 4, April – 2020

[51] Šram, Z. (2014). Eksplorativna i konfirmatorna faktorska analiza skale nacionalističkog sindroma, *Političke perspektive: Časopis za istraživanje politike,* Vol.4 (1), pp. 8.-30

[52] Vinh, T. T. & Phuong, T. T. K. (2017). Examining the interrelationships among destination brand image, destination perceived quality, tourist satisfaction, and tourist loyalty: evidence from Danang city, Vietnam. *International Journal of Tourism Policy,* 7(4), pp. 352-374

[53] Zeithaml, V.A., (1988). "Consumer perceptions of price, quality, and value: a means-end model synthesis of evidence", *Journal of Marketing,* Vol. 52(3), pp. 2-22.

[54] Zhang, Y. (2015). The Impact of Brand Image on Consumer Behavior: A Literature Review Open, *Journal of Business and Management,* Vol (3(1), pp. 58-62

[55] The Economic Times (30 July 2023), https://economictimes.indiatimes.com/definition/brands

Preliminary communication / Prethodno priopćenje

HOW DO WE BEHAVE IN A DIGITAL ENVIRONMENT? – THE IMPACT OF DIGITAL MARKETING ON CONSUMER BEHAVIOR

VALENTINA (ČABULA) MEDVEN, mag. oec., student
Karlovac University of Applied Sciences
Trg J. J. Strossmayera 9, 47000 Karlovac, Croatia
valentina.cabula@gmail.com

TIHANA CEGUR RADOVIĆ, Ph. D., Senior Lecturer
Karlovac University of Applied Sciences
Business Department
Trg J. J. Strossmayera 9, 47000 Karlovac, Croatia
tcradovic@vuka.hr

MIRJANA CIBULKA, mag. educ. philol. angl., Lecturer
Karlovac University of Applied Sciences
Safety and Protection at Work
Trg J. J. Strossmayera 9, 47000 Karlovac, Croatia
mirjana.cibulka@vuka.hr

ABSTRACT

The purpose of this paper is to determine the impact of digital marketing on consumer behavior in a digital environment, their online purchase decision, satisfaction with online shopping and risk perception. The goal was to investigate the relationship between the impact of different factors of digital marketing on consumer decision to purchase products online, their satisfaction and risk perception. An analysis of the recent literature on the topic of digital marketing, consumer behavior, online purchase decision, satisfaction and risk perception was performed. Empirical research was conducted on a convenience sample of 200 respondents. Descriptive and multivariate statistics were used in the data analysis. Data analysis was performed using the software package IBM SPSS Statistic Version 23. The results of the research show that online reviews have an important impact on customer online purchase decision. The results also show that there is a positive and significant impact between online purchase decision and customer satisfaction and a weak relationship between risk perception and customer satisfaction. The research represents a starting point for further research on online consumer behavior, factors affecting their online purchase decision and risk perception reduction. Furthermore, the results can help online sellers develop strategies and tactics that can have a positive impact on online customer purchase decision and risk perception reduction.

KEYWORDS: digital marketing, consumer behavior, online purchase decision, consumer satisfaction, risk perception

1. INTRODUCTION

Digital marketing has created many new opportunities on the Internet, and its role has been rapidly growing in recent years [Anumolu et al., 2015]. It can be defined as the use of information and communication technology to support marketing activities for better customer satisfaction [Veleva and Tsvetlanova, 2020]. The Internet provides consumers with much quicker access to information and sellers than other sales channels. Consumers have access to supplier and manufacturer websites, comparison sites, discussion forums and ads. The Internet has also diminished the gap between different societies. More and more customers are buying global products and services at local prices, causing companies' cost structures to become globally competitive. Digital marketing has also led to behavioral changes in the digital environment compared to the traditional marketing environment. Not only has behavior changed, but consumers have also acquired entirely new characteristics.

The aim of this study is to determine the influence of digital marketing on consumer behavior, the factors affecting online purchase decision, how online purchase decision affect customer satisfaction and how risk perception affects customer satisfaction.

The following auxiliary hypotheses were formulated:
H1: There is a positive relationship between online reviews and online purchase decision.
H2: There is a positive relationship between online purchase decision and customer satisfaction.
H3: There is a weak relationship between risk perception and customer satisfaction.

The empirical research was conducted online using the Google Forms platform on a sample of 200 respondents on a convenient sample through e-mails and social networks. Descriptive and multivariate statistics were used in the data analysis. The data analysis was performed using IBM SPSS Statistic Version 23 software.

The paper consist of five chapters. The introductory part, is followed by description of the main constructs used in the paper, description of the methodology, and results of the empirical research. Discussion and conclusions of the research are given at the end of the paper.

2. THEORETICAL FRAMEWORK

2.1. DIGITAL MARKETING

Digital marketing represents achieving marketing goals using digital technologies. Characteristics of a consumer in the digital environment include: being well-informed due to technological progress, being self-directed and difficult to influence**,** fast paced lifestyle, being selective and comparing different options before making purchase decisions, being volatile, and displaying contradictory behaviors, as well as staying constantly connected using technology like smartphones and wearable devices to cover up differences between online and offline world [Legler, 2015]. Despite these characteristics, online consumers exhibit heterogeneous behaviors. Nonetheless, online consumer behavior follows the same decision-making phases, which include problem recognition, information search, and evaluation of alternatives, purchase decision and post-purchase behavior [Kotler and Armstrong, 2018]. Understandably, consumers allocate more attention to purchasing an automobile than to routine purchases like

laundry detergent or juice. Consequently, buying a car assumes a high degree of involvement, while purchasing laundry detergent implies low involvement [Schwarzl and Grabowska, 2015].

In the information search, evaluation, and decision-making phases, consumers in the digital environment manifest the following characteristic behaviors: consumers seek and receive personalized products; they are influenced by online reviews and sources from social media as well as offline sources and they are impacted by recommendations from other consumers [Muller et al., 2011]. Customer review is defined as any positive or negative statement made by customers on online platforms [Park and Kim, 2008]. It gives a customer more reasons to make decisions and increases decision-makers confidence in the decisions taken [Dwidienawati et al., 2020]. Customer review can reduce the risk perceived by customers and improve the degree of satisfaction and their efficiency in making decisions [Yan et al., 2016]. Beneke et al., [2016] considers customer review as an Internet tool used by the global community to exchange information about products and services. Social media influencers represents a person who represents companies through branded content on social media account such as Facebook, Instagram, Snapchat, Twitter and YouTube [Pereira et al., 2023]. They are users with a high number of followers on their digital channels and they are able to monetize their audience by introducing sponsored content in their photos, videos and texts [Abidin, 2016]. In the post-purchase phase, the consumers in the digital environment manifest behaviors of social media providing direct communication between the customer and the brand, thus influencing consumer behavior and effectively turning consumers into virtual journalists or public relations experts [Ugonna et al., 2017].

2.2. ONLINE PURCHASE DECISION

An online purchase decision is an action performed by someone to select the best option from range of options [Hidayat et al., 2021]. Before making a purchase, consumers must make many decisions that are based on the willingness to satisfy their needs [Hartanto et al., 2022]. The online shopping decision process is similar to the in-store shopping decision process, but there are some differences. On the Internet, customers have access to more information and can compare more alternatives than in a store. Customers can also purchase products or services 24/7. E-retailers continuously invest in online purchase decision ads to help customers with on-line shopping [Tang, 2020]. Social networks usage influences the purchase decision process of the customer [Prasad et al., 2018]. The opinions of friends, colleagues and relatives posted on social networks can have a significant impact on consumer purchasing decisions [Schwarzl and Grabowska, 2015; Liang et al., 2020]. Furthermore, product recommendations of friends and colleagues on online social networks have a significant impact on the customers' online purchase decision [Li et al., 2021]. A high degree of trust stimulates and meets high expectations of customers; satisfies transactions, eliminates risk perception, uncertainty and interdependence [Pavlou, 2003]. Satisfied customers become brand advocates, while dissatisfaction can lead to negative attitudes, creating cognitive dissonance. Online communication significantly influences online purchase decisions [Prasad et al., 2018], especially the use of social media and electronic word-of-mouth [Chevalier and Mayzlin, 2006; Prasad et al., 2017].

2.3. RISK PERCEPTION

Risk is one of most significant problem of online shopping [Farivar et al., 2017]. Consumers perceive higher levels of risk when shopping online then in traditional distribution channels due to limited physical access to products and sales personnel [Dai et al., 2014]. They feel unsure

and vulnerable [Chung et al., 2015] and apply tactics that mitigate their risks [Verma and Pant, 2021]. Online risk perception can be defined as the feeling of insecurity and vulnerability experienced while browsing a website [Alcántara-Pilar et al., 2015]. Risk perception or perceived risk is defined as any uncertainty perception by the customer about an unforeseen consequence due to purchase [Cox, 1967], consumers' feelings of likelihood and unpleasant consequence [Cunningham, 1967] or an attribute of an alternative decision reflecting the variance of its possible outcomes [Gefen et al., 2002, Verma and Pant, 2021:294]. Kim et al., [2008] defined risk perception as a customer's belief about the potential uncertain negative outcomes from the transaction. Farivar et al. [2018] defined risk perception as the customers' uncertainty feelings regarding a possible negative outcome of using a product or a service due to an inability to evaluate the product prior purchase or return of products [Aghkyan-Simonian et al., 2012; Verma and Pant, 2021]. Risk perception is a multidimensional construct consisting of financial risk, product risk and information risk [Bhatnager et al., 2000]. Shopping includes risk because a retailer's decision may have results which the customer cannot predict perfectly, and the outcome of some decisions could be unpleasant for the customer [Bauer 1960; Chiu et al., 2012].

2.4. CONSUMER SATISFACTION

Consumer satisfaction is defined as evaluation and judgment of a product or service that successfully provides a pleasurable level of consumption-related fulfillment [Oliver, 1993, 2010]. Consumer satisfaction in an online context can be defined as the user's contentment with their purchasing experience on the Internet [Andersen and Srinivasan, 2003]. Satisfactory online experience plays a crucial role in users' overall evaluation of website quality and their online purchase intention [Tang and Jang, 2008]. Online customer satisfaction comes from customer service quality experience and through online service process [Zhou et al., 2019]. Consumer heterogeneity with different risk perception in online service process [Song and Hu, 2019] can affect customer purchase behavior [Song et al., 2021] and their satisfaction. Online customers are satisfied if the perceived performance matches their expectations [Al-Adwen and Al-Horani, 2019]. The results of Javed et al. [2020] research have proven that post-sale services from online retailers are important determinants in the cumulative online customer satisfaction. Verma and Pant [2021] have developed a new input output framework by including price verification, product display, social influence and risk perception of online grocery shoppers and have proved that product display is negatively influenced by risk perception. Curras-Perez and Sanchez-Garcia [2012] researched online sales of air tickets and concluded that satisfaction has a stronger effect on purchase intent in the case of consumers' higher risk perception. The influence of satisfaction on commitment is weaker in consumers with a higher level of perceived risk [Curras-Perez and Sanchez-Garcia, 2012].

2.5. RESEARCH HYPOTHESES

The fundamental online tools of digital marketing include: websites, email marketing, content marketing, social media platforms (Facebook, Twitter, LinkedIn, Instagram, and others), blogs, SEO optimization, Big data marketing, Online advertising, visual marketing (YouTube), mobile marketing, wearable devices, Internet of Things and Games [Veleva and Tsvetlanova, 2020]. In the past decade, Internet strategies have been evaluating rapidly. In response to the challenges of the modern era, users have adapted their behavior to the Internet. These changes have led to the development of new user habits and behaviors in the digital environment, increasingly characterized by personalized strategies for attracting new customers. In the digital environment where companies need to understand their users and consumers, the new models

or customer behavior on the Internet should encompass constructs such as customer experience, influencer marketing and user-generated content (UGC) [Saura et al., 2020]. In the digital environment, online reviews [Chou et al., 2013; Dwidienawati et al., 2020; Hartanto et al., 2022], the Influencers [Pereira et al., 2023] and sources from social media as well as offline sources influence the consumers' purchase decision. The digital environment enables consumers to leverage recommendations and information gathered from different types of consumers [Muller et al., 2011]. Based on the above, a study hypothesis can be proposed: *H1: There is a positive relationship between online reviews and online purchase decision.*

Customer satisfaction is a consequence of the customer experience during the purchase process and its role is very important in future customer behavior, such as online repurchase intention and loyalty [Pereira et al., 2016]. Hossain et al. [2018] have proven that QR codes have significant impact on purchase decision and customer satisfaction. Online purchase decision positively affects customer satisfaction [Hartanto et al., 2023]. A satisfied online customer would likely shop again and recommend online shopping to others, while a dissatisfied customer would leave his online retailers with or without any complaints [Pereira et al., 2017]. Taking into account the above mentioned, the following hypothesis can be proposed: *H2: There is a positive relationship between online purchase decision and customer satisfaction.*

In Chen et al. [2015] research risk perception has a significant negative impact on customer satisfaction. In the online shopping environment customers often, make a purchase before experiencing a product so risk perception is an important antecedent of customer satisfaction [Moon and Armstrong, 2020]. Risk perception in e-commerce has a significant negative impact on attitudes towards online shopping [Shih, 2004], intention to shop on the Internet [Pavlou, 2003], and Internet purchasing behavior [Bodmer, 2009, Moon and Armstrong, 2020]. Moon and Armstrong [2020] research investigated how online-to-offline service quality affects risk perception and trust, and how this customer perception influences customer satisfaction. High level of service quality should improve the perceived trust and reduce risk perception of the products and services, low risk perception, and high-perceived trust have a positive effect on customer satisfaction. The results of Alcántara-Pilar et al. [2017] research revealed that tourist online satisfaction, perceived website usability and online risk perception are significant antecedents that influence the affect towards a travel destination generated online. The higher online risk perception, the lower the effect on a travel destination. Therefore, the following hypothesis can be proposed: *H3: There is a weak relationship between risk perception and customer satisfaction.*

3. RESEARCH METHODOLOGY

3.1. MEASUREMENT SCALES

To achieve the purpose and goals of the paper, an empirical study was conducted on a convenience sample of respondents (N=200). Scales from previous studies were used. They were translated into Croatian and adapted to field of digital marketing and online purchase decision. The attitudes of the respondents were measured using a Likert scale for evaluating attitudes, ranging from 1 to 5 (1 – completely disagree, 5 – completely agree). The factors affecting online purchase decision consist of 5 variables. They were measured using the adopted customer review scale created by Hartanto et al., [2022] and other variables were adopted from Periera et al., [2023] scale. The online purchase decision was measured using the adopted Hanaysha [2018] scale. It consists of 3 variables. The customer satisfaction was measured using

the satisfaction with the purchase experience scale by Walsh and Sharon [2007], which consists of 3 variables. Risk perception was measured using the Internet usage riskiness scale created by Schlosser et al., [2006] and adopted to research. It consists of 3 variables. The construct and the accompanying variables are shown in Table 1.

Table 1. Constructs and variables

Construct	Item number	Item	Sources
FACTORS AFFECTING ONLINE PURCHASE DECISION	F1	Messages from Influencers can have an influence on my purchase decision.	Periera et al., (2023)
	F2	Sponsored articles published on the Internet can have an influence on my purchase decision.	
	F3	Ads related to some product or service I searched online (remarketing) could have an influence on my purchase decision.	
	F4	Online reviews can have an influence on my purchase decision.	Hartanto et al. (2022)
	F5	Online reviews help me make better purchase decision.	
ONLINE PURCHASE DECISION	OPD1	I often buy products or services online.	Hanaysha (2018)
	OPD2	Overall, I am satisfied with purchasing product or services online.	
	OPD3	I will positively recommend online shopping to others.	
SATISFACTION	S1	I am satisfied with the products and services bought online.	Walsh and Sharon (2007)
	S2	I am satisfied with the delivery service of the products purchased to your home address.	
	S3	I am overall satisfied with online shopping.	
RISK PERCEPTION	RP1	Sharing and sending personal data via Internet is risky for me.	Schlosser et al. (2006)
	RP2	Internet is a safe place for shearing and sending personal data.	
	RP3	I feel safe when sending my personal data via Internet.	

Source: Authors'

3.2. DATA COLLECTION AND SAMPLE

The data were collected from 200 respondents. The questionnaire was sent online as a Google Form through social networks and e-mail. Table 2 shows the sample description based on gender, age and how often respondents purchase products or services online.

Table 2. Sample structure (N=200)

Characteristics	Total	
	N	%
Gender		
Female	134	67.0
Male	66	33.0
Age		
18 – 25	47	23.5
26 – 35	90	45.0
36 – 45	43	21.5
46 – 55	11	5.5

56 – 65	8	4.0
Over 66	1	0.5
How often do you purchase products or service online?		
often	74	37.0
sometimes	87	43.5
rarely	36	18.0
never	3	1.5

Source: Authors'

Sample structure analysis shows that more women (67%) than man (48.8%) participated in the survey. The respondents were mainly younger people, between 26 and 35 years old (45%). The reason was that younger people spend more time on Internet purchasing product and services online then the elderly who are more traditional and still purchase product and services in stores. Regarding the question, *How often do they purchase products or services online?,* 43.5% of the respondents purchase products and services sometimes, while 37% of them buy them more often.

4. FINDINGS

The data analysis included a descriptive statistical analysis of the construct factors affecting online purchase decision, online purchase decision, customer satisfaction and risk perception and reliability analysis and dimensionality of the measurement scales. The descriptive analysis (Table 3) was conducted first, followed by the exploratory factor analysis to determine the dimensionality of the measurement scales. The reliability analysis was measured using the Cronbach alpha (Table 3). The multiple regression analysis of constructs, the factors affecting online purchase decision and the online purchase decision was applied to determine the influence of the factors affecting the online purchase decision on online purchase decision of online customers. The correlation analysis was used to compare the relationship between the constructs: online purchase decision, risk perception and customer satisfaction.

4.1. DESCRIPTIVE ANALYSIS

The descriptive analysis was conducted of the variables of constructs factors affecting online purchase decision, online purchase decision, consumer satisfaction and risk perception (Table 3).

Table 3. Descriptive statistics of variables and Cronbach alpha

Construct	Item number	Item	Arithmetic mean	Mode	Std. Dev.	Cronbach alpha
FACTORS AFFECTING ONLINE PURCHASE DECISION	F1	Messages from Influencers can have an influence on my purchase decision.	2.70	3	1.257	.784
	F2	Sponsored articles published on the Internet can have an influence on my purchase decision.	3.01	3	1.089	
	F3	Ads related to some product or service I searched online (remarketing) could have an influence on my purchase decision.	3.27	4	1.064	
	F4	Online reviews can have an influence on my purchase decision.	3.86	5	1.175	
	F5	Online reviews help me make better purchase decision.	4.05	5	1.058	

ONLINE PURCHASE DECISION	OPD1	I often buy products or services online.	3.97	4	1.109	0.683
	OPD2	Overall, I am satisfied with purchasing product or services online.	4.16	5	0.886	
	OPD3	I will positively recommend online shopping to others.	4.00	5	0.977	
SATISFACTION	S1	I am satisfied with the products and services bought online.	4.00	4	0.830	.721
	S2	I am satisfied with the delivery service of the products purchased to your home address.	4.07	5	0.967	
	S3	I am overall satisfied with online shopping.	4.19	4	0.739	
RISK PERCEPTION	RP1	Sharing and sending personal data via Internet is risky for me.	3.61	3	1.131	.607
	RP2	Internet is a safe place for shearing and sending personal data.	2.69	3	1.114	
	RP3	I feel safe when sending my personal data via Internet.	2.89	3	1.069	

Source: Authors'

The arithmetic means of the variables of the factors affecting purchase decision constructs (F) range from 2.70 to 4.05. Variable F1 has the lowest score, while the variable F5 has the highest score. Mode ranges from 3 to 5. The values of the standard deviation exceed 1, pointing to data dispersion. The variables of the arithmetic mean of online purchase decision construct (OPD) range from 3.97 to 4.00. The variable OPD1 has the lowest value while the variable OPD2 has the highest score. The mode range from 4 to 5. The values of the standard deviation are all below 1, except the variable OPD1. The values of the arithmetic mean with the regard to the customer satisfaction construct (S) range from 4 to 4.19. The variable S1 has the lowest value, and the variable S3 has the highest value. The mode range from 4 to 5. The values of the standard deviation are all below 1, so there is not any dispersion. The arithmetic mean of the variables of the risk perception construct (RP) range from 2.69 to 3.61. The variable RP2 has the lowest value and the variable RP1 has the highest value. All modes equal 3. The values of the standard deviation exceed 1, pointing to data dispersion.

4.2. VALIDATION OF THE MEASUREMENT SCALES

To determine the validity of the research instrument, an analysis of the dimensionality and reliability of the measurement scales was performed. The reliability of the measurement scales was confirmed by applying Cronbach's alpha coefficient of internal consistency. For the measurement scale of the factors affecting online purchase decision, dimensionality analysis was conducted using exploratory factor analysis. The results show that the adequacy measures of factors affecting online purchase decision construct are appropriate (KMO is 0.685, and Bartlett's test sphericity χ^2= 353.253; p<0.001). Principal component analysis with varimax rotation of the factor axis was carried out. Table 4 shows that two factors were extracted using exploratory factor analysis for the factors affecting online purchase decision construct. Total percentage of the explained variance shows that the extracted factors contain 75.682% of information of all variables. This is a high percentage and points to a good relationship among the variables [Hair 2014: 115]. The eigenvalue of each extracted factor is over 1. The factor loadings for all factors are positive and exceed 0.50, which is considered high loading [Hair, 2014:115]. The number of variables in each factor is 3 and 2. Factor 1 is called "Digital marketing tools"; it contains 3 variables, which explains 53.926% of variance. Cronbach alpha is 0.805 which is considered high reliability [Petersen, 1994]. Factor 2 is called "Online reviews". It contains 2 variables, which explains 21.756% of variance. Cronbach alpha is 0.759 which is considered good reliability [Petersen, 1994].

Table 4. Exploratory factor analysis of the factors affecting online purchase decision

Item number	Variable	Factor loadings	Total variance explained (%)	Cronbach alpha
FACTOR 1 – DIGITAL MARKETING TOOLS			**53.926**	**0.805**
F1	Messages from Influencers can have an influence on my purchase decision.	.786		
F2	Sponsored articles published on the Internet can have an influence on my purchase decision.	.900		
F3	Ads related to some product or service I searched online (remarketing) could have an influence on my purchase decision.	.802		
FACTOR 2 – ONLINE REVIEWS			**21.756**	**0.759**
F4	Online reviews can have an influence on my purchase decision.	.904		
F5	Online reviews help me make better purchase decision.	.849		

Source: Authors'

Regarding, exploratory factor analysis of the online purchase decision construct, one factor was extracted. Total percentage of the explained variance shows that the extracted factors contain 62.360% of information of all variables. The factor loadings of all variables are positive and it exceeds 0.50. The number of variables is 3. Also, one factor was extracted using exploratory factor analysis of the consumer satisfaction construct. Total percentage of the explained variance shows that the extracted factors contain 66.213% of information of all variables. The factor loadings of all variables are positive and it exceeds 0.50. The number of variables are 3. The construct risk perception (information risk) had one factor which was extracted using exploratory factor analysis. Variable RP1 *Sharing and sending personal data via Internet is risky for me.* had a factor loading of 0.297 and was excluded from the further analysis. Total percentage of the explained variance shows that the extracted factors contain 82.060% of information of all variables. The factor loadings of all factors are positive and exceeds 0.50. The number of variables are 2.

Reliability analysis was conducted on the construct of online purchase decision, customer satisfaction and risk perception. The Cronbach alpha range from 0.629 to 0.781. Values of 0.7 are considered good reliability [Peterson, 1994].

Table 5. Multiple regression analysis for constructs factors affecting the online purchase decision and the online purchase decision

Independent variables	B	Std. Error	Beta	t	Sig.
(Constant)	7.680	.653		11.755	.000
DIGITAL MARKETING TOOLS	.115	.056	.143	2.047	.042
ONLINE REVIEWS	.431	.081	.370	5.316	.000
R2	0.447				
Adjusted R2	0.192				
Standard error	2.09937				
F ratio	24.603				
Significance	0.000				

Source: Authors'

The results of the regression analysis are statistically significant (F=24.603, p=0.000). The determination coefficient (R^2) totals 0.431, and the variables in the model share 43.1% of the common factors. The analysis confirms that the online reviews (β=0.370, p=0.000) have a considerable and significant impact on the online purchase decision, while digital marketing tools (β=0.143 p=0.042) are not considerable and are significant at level 0.05.

To confirm the relationship between the online purchase decision and the customer satisfaction, a correlation analysis was conducted using the Pearson correlation coefficient. A statistically positive medium relationship between the online purchase decision construct and the customer satisfaction construct (r=0.644, p=0.000) was established. Regarding a correlation analysis between constructs the risk perception and the customer satisfaction (r=0.258, p=0.000), a statistically significant but very weak correlation was established.

5. DISCUSSION AND CONCLUSION

This paper aims to empirically analyze which digital marketing factor have positive relationship on the online purchase decision and weather the online purchase decision and risk perception have positive effects on customer satisfaction. To achieve this goal, three hypotheses were set. A measuring instrument was designed and empirical research was carried out, which has resulted in important findings. The scale for measuring the factors affecting the online purchase decision was adopted and its reliability and dimensionality were verified. The results confirmed the validity of the scale for its application in the context of the factors affecting the online purchase decision.

The result of multiple regression analysis prove the first hypothesis (H1). There is a positive relationship between online reviews (β=0.370, p=0.000) and the online purchase decision. The customers often read other online reviews to find out what other customers experiences are about a products or services they purchase. It can be concluded that H1 hypothesis is supported.

The result of testing the hypothesis H2 align with the results of previous research conducted by Hossain et al., [2018] and Hartanto et al., [2023]. In this paper the online purchase decision positively affects customer satisfaction (r=0.644, p=0.000). Therefore, satisfied customers intend to purchase products or services online more often, and recommend it to others. Overall, customers are satisfied with purchasing products online. The H2 hypothesis was supported. Based on the result of H3 hypothesis testing, it is proven that there is a weak correlation (r= 0.258, p=0.000) between risk perception and customer satisfaction. The results of testing this hypothesis are in line with the results of previous research conducted by Chen et al., [2015], Alcántara-Pilar et al. [2017] and Moon and Armstrong [2020]. The online customers are unable to physically assess the product before the purchase so sellers offer cues designed convey the quality of product or services offered, reduce risk perception and increase purchasing behavior [Mavlanova et al., 2016; Rosillo-Diaz et al., 2019].

It can be concluded that online reviews positively affect online purchase decision and online purchase decision positively affects customer satisfaction. There is significant but weak relationship between risk perception and customer satisfaction, which implies that further research must be conducted.

The implication of this research can provide significant contributions and benefits to the literature research. The theoretical implications provide scientific contribution and empirical

research by analyzing relationship between the constructs: factors affecting online purchase decision, online purchase decision, risk perception and customer satisfaction. The practical implication is to contribute to the development of digital marketing and online shopping by identifying factors affecting online purchase decision and building customer satisfaction. Also, online sellers must find a way to build trust with online customers by reducing risk perception especially regarding information risk so customers can feel safe when giving their personal data on Internet.

There are several limitations to this study. The research was conducted online and the respondents were mainly younger people. Further studies should be carried out on larger samples with different age groups. Further studies could investigate the influence of other constructs, such as loyalty, purchase intentions, other factors affecting online purchase decision, service quality and perceived value. In addition, a segmentation of different types of online customers can be made. There are also many cultural differences regarding online purchase decision making and risk perception so further research can be conducted with the sample of online customers between different countries and cultures.

REFERENCES

[1] Abidin, C. (2016). Visibility labour: Engaging with Influencers' fashion brands and #OOTD advertorial campaigns on Instagram. *Media International Australia*, 161, pp 86–100, 2016.

[2] Aghekyan-Simonian, M., Forsythe, S., Kwon, W. S., & Chattaraman, V. (2012). The role of product brand image and online store image on perceived risks and online purchase intentions for apparel. Journal of Retailing and Consumer Services, 19(3), 325-331. https://doi.org/10.1016/j.jretconser.2012.03.006

[3] Al-Adwan, A. S., and Al-Horani, M. A. (2019). Boosting customer E-loyalty: an extended scale of online service quality. *Information*, 10:380, 2019., https://doi.org/10.3390/ info10120380

[4] Alcántara-Pilar, J. M., Blanco-Encomeinda, F. J., Armenski, T., Del Barrio-García, S. (2017). The antecedent role of online satisfaction, perceived risk online, and perceived website usability on the affect towards travel destinations. *Journal of Destination Marketing & Management*, pp 1-16, 2017., http://dx.doiorg/10.1016/j.jdmm.2017.09.005.

[5] Alcántara-Pilar, J. M., Del Barrio-García, S., Porcu, L., Crespo-Almendros, E. (2015). Motivational duality in online consumer behaviour: Website usability and flow state as moderating factors. *International Journal of Business and Economics*, 14(1), pp 79–104, 2015.

[6] Anderson, R. E., Srinivasan, S. S. (2003). E-satisfaction and e-loyalty: A contingency framework. *Psychology and Marketing*, 20(2), 123–138.

[7] Anumolu, K., Prasad H. C., S., Gopalkrishna, A. (2015). A Digital Marketing: A Strategic Outreaching Process. *International Journal of Management, IT and Engineering*, 7(5), pp 254-260, 2015.

[8] Bauer, R. A. (1960). *Consumer behavior as risk taking*. In: Hancock, R. (ed) Dynamic marketing for a changing world. American Marketing Association, Chicago, pp 389–398, 1960.

[9] Beneke, J., Sousa, S. D., Mbuyu, M., Wickham, B. (2016). The effect of negative online customer reviews on brand equity and purchase intention of consumer electronics in

South Africa. *The International Review of Retail, Distribution and Consumer Research*, 26(2), pp 171–201, 2016.
[10] Bhatnagar A., Misra S., Rao H. R. (2000). On risk, convenience, and internet shopping behavior. *Communication of the ACM*, 43(11), pp 98–114, 2000.
[11] Bray, J. (2008). Consumer Behaviour Theory: Approaches and Models. https://eprints.bournemouth.ac.uk/10107/1/Consumer_Behaviour_Theory_Approaches_%26_Models.pdf [01.08.2023]
[12] Chevalier, J.A. and Mayzlin, D. (2006). The effect of word of mouth on sales: online book Chung, reviews. *Journal of Marketing Research*, 43(3), pp. 345-354, 2006.
[13] Chiu, C. M., Hsu M. S., Lai H., Chang, C. M. (2012). Re-examining the influence of trust on online repeat purchase intention: the moderating role of habit and its antecedents. *Decision Support System, 53(4)*, pp 835–845, 2012.
[14] Cox, D. F. (1967). *Risk handling in consumer behavior: An intensive study of two cases.* In Risk taking and information handling in consumer behavior, pp 34-81. Harvard University Press
[15] Cunningham, S. M. (1967). *The major dimensions of perceived risk. Risk taking and information handling in consumer behavior.* Harvard University.
[16] Dai, B., Forsythe, S., & Kwon, W. S. (2014). The impact of online shopping experience on risk perceptions and online purchase intentions: Does product category matter?. *Journal of Electronic Commerce Research*, 15(1), pp 13–24, 2014.
[17] Dwidienawati, D., Tjahjana, D., Bramantoro, S., & Gandasari, D. (2020). Customer review or influencer endorsement : which one influences purchase intention more? *Heliyon*, 6(11), pp 1–11, 2020, https://doi.org/10.1016/j.heliyon.2020.e05543
[18] Farivar, S., Turel, O., Yuan, Y. (2017). A trust-risk perspective on social commerce use: An examination of the biasing role of habit. *Internet Research*, 27(3), pp. 586–607, 2017, https://doi.org/10.1108/IntR-06-2016-0175
[19] Farivar, S., Turel, O., Yuan, Y. (2018). Skewing users' rational risk considerations in social commerce: An empirical examination of the role of social identification. In *Information & Management, 2018.*
[20] Gil-Gomez, H., Guerola-Navarro, V., Oltra-Badenes, R., Lozano-Quilis, J. A. (2020). Customer relationship management: digital transformation and sustainable business model innovation, *Economic Research*, 33(1), pp 2733-2750, 2020.
[21] Hanaysha, J. R. (2018). An examination of the factors affecting consumer's purchase decision in the Malaysian retail market, *PSU Research Review*, 2(1), pp 7–23, 2018, https://doi.org/10.1108/PRR-08-2017-0034
[22] Hartanto, N., Mani, L., Jati, M., Josephine, R., Hidayat, Z. (2022). Factors Affecting Online Purchase Decision, Customer Satisfaction, and Brand Loyalty: An Empirical Study from Indonesia's Bigget E-Commerce. *Journal of Distribution Science*, 20(11), pp. 33-45, 2022.
[23] Hendriyani, C., Auliana, L. (2018). Transformation from Relationship Marketing to Electronic Customer Relationship Management: A Literature Study. *Review of Integrative Business and Economics Research*, 7(2), 2018.
[24] Hidayat, A., Wijaya, T., Ishak, A., Catyanadika, P. E. (2021). Consumer trust as the antecedent of online consumer purchase decision. Information, 12(4), 145, 2021.
[25] Javed, M. K., and Wu, M. (2020). Effects of online retailer after delivery services on repurchase intention: an empirical analysis of customers' past experience and future confidence with the retailer. *Journal of Retailing and Consumer Services,* 54, 101942, 2020., https://doi.org/10.1016/j.jretconser.2019.101942

[26] Kim D. J., Ferrin D. L., Rao H. R. (2008). A trust-based consumer decision-making model in electronic commerce: the role of trust, perceived risk, and their antecedents. *Decision Support System,* 44(2), pp 544–56, 2008.
[27] Kotler, Ph., Armstrong, G. (2018). *Principle of Marketing*, Pearson Education, New York, USA
[28] Li, Y. H., Kou, G., Li, G. X., Wang, H. M. (2021). Multi-attribute group decision making with opinion dynamics based on social trust network. *Information Fusion,* 75, pp 102–115, 2021.
[29] Legler, S. (2015). Digital CRM 2.0: Building customer relationships in the digital landscape, *Deloitte,* 2015.
[30] Liang, Q., Liao, X., Shang, J., 2020. A multiple criteria approach integrating social ties to support purchase decision. Computers & Industrial Engineering, 147, 106655, 2020.
[31] Mavlanova, T., Benbunan-Fich, R., Lang, G. (2016). The role of external and internal signals in e-commerce. *Decision Support Systems*, 87, pp 59-68, 2016.
[32] Moon, Y., Armstrong, D., J. (2020). Service quality factors affecting consumer attitudes in online-to-offline commerce. *Information Systems and e-Business Management*, 18(1), pp 1-34, 2020.
[33] Muller, P., Damgaard, M., Litchfield, A., Lewis, M., Hörnle, J. (2011). Consumer behaviour in a digital environment. European Parliament's Committee on Internal Market and Consumer Protection, 2011.
[34] Nguyen, D., H., de Leeuw, S., Dullaert, W. (2018). Consumer Behaviour and Order Fulfilment in Online Retailing: A Systematic Review. *International Journal of Management Reviews*, 20, pp 255–276, 2018.
[35] Oliver, R. L. (1993). Cognitive, affective and attributes of the satisfaction response. *Journal of Consumer Research,* 20(2), pp 418–430.
[36] Oliver, R. L. (2010). *Satisfaction: A behavioral perspective on the consumer (2nd ed.)*. Armonk, NY: M.E. Sharpe, 2010.
[37] Onete, C. B., Teodorescu, I., Vasile, V. (2016). Analysis Components of the Digital Consumer Behavior in Romania, *Amfiteatru Economic Journal*, ISSN 2247-9104, 43(18), pp 654-662, 2016.
[38] Park, D., Kim, S. (2008). The effects of consumer knowledge on message processing of electronic word-of-mouth via online consumer reviews, *Electronic Commerce Research and Applications*, 7(4), pp 399–410, 2008.
[39] Pavlou, P. A. (2003). Consumer acceptance of electronic commerce: integrating trust and risk with the technology acceptance model. *International Journal of Electronic Commerce*, 7(3), pp 101-134, 2003.
[40] Peterson, R. A. (1994). A meta-analysis of Cronbach's Coefficient Alpha. *Journal of Consumer Research,* 21(2), pp 381-391, 1994.
[41] Pereira, J. M. S., Cardoso, A., Canavarro, A., Figueiredo, J., Garcia, J. E. (2023). Digital Influencers' Attributes and Perceived Characterization and Their Impact on Purchase Intentions. S*ustainability*, 15, 12750, 2023., https://doi.org/10.3390/su151712750
[42] Pereira, H. G., Salgueiro, M., & Rita, P. (2016). Online purchase determinants of loyalty: The mediating effect of satisfaction in tourism. *Journal of Retailing and Consumer Services*, 30, pp 279– 291, 2016.
[43] Pereira, H. G., Salgueiro, M. D. F., Rita, P. (2017). Online determinants of e-customer satisfaction : application to website purchases in tourism. *Service Business*, 11(2), pp 375–403, 2017, https://doi.org/10.1007/s11628-016-0313-6
[44] Prasad, S., Garg, A., Prasad, S. (2019). Purchase decision of generation Y in an online environment. *Marketing Intelligence & Planning*, 0263-4503, 2019., https://doi.org/10.1108/MIP-02-2018-0070

[45] Prasad, S., Gupta, I.C. and Totala, N.K. (2017). Social media usage, electronic word of mouth and purchase-decision involvement. *Asia Pacific Journal of Business Administration*, 9(2), pp 134-145, 2017.
[46] Ramyan, N., Ali, M. (2016). Factors affecting consumer-buying behavior. *International Journal of Applied Research*, 10(2), pp 76-80, 2016.
[47] Rosillo-Diaz, E., Blanco-Encomienda, F., J., Crespo-Almendros, E. (2020). A cross-cultural analysis of perceived product quality, perceived risk and purchase intention in e-commerce platforms. Journal of Enterprise Information Management, 33(1), pp 139-160, 2020.
[48] Ryan, D. (2014). *Understanding Digital Marketing*. Kogan Page, Third edition, 2014.
[49] Sandeep P., Arjita J. (2018). Digital Marketing: Concepts & Aspects. *International Journal of Advancred Resarch* 7(2), pp 260-266, 2014.
[50] Saura, J., Reyes-Menendez, A.,Matos, N., Correia, M., Palos-Sanchez, P. (2020). Consumer Behavior in the Digital Age. *Journal of Spatial and Organizational Dynamics*, 8, pp 190-194, 2020.
[51] Schlosser, A. E., White, T. B., Lloyd, S. M. (2006). Converting Web Site Visitors into Buyers: How Web Site Investment Increases Consumer Trusting Beliefs and Online Purchase Intentions. *Journal of Marketing,* 70 (2), pp 133-148, 2006.
[52] Schwarzl, S. Grabowska, M. (2015). Online marketing strategies: The future is here. *Journal of International Studies*. 8, pp 187-196, 2015.
[53] Song, Y.M., Hu, J., 2019. Large-scale group decision making with multiple stakeholders based on probabilistic linguistic preference relation. *Applied Soft Computing*, 80, pp 712–722, 2019.
[54] Song, Y., Li, G., Li, T., Li, Y. (2021). A purchase decision support model considering consumer personalization about aspirations and risk attitudes. *Journal of Retailing and Consumer Services*, 63, pp 1-11, 2021.
[55] Song, Y. M., Li, G. X., Ergu, D. J., Liu, N. (2021). An optimization-based method to conduct consistency and consensus in group decision making under probabilistic uncertain linguistic preference relations. *Journal of the Operational Research Society*, pp 1-15, 2021., https://doi.org/10.1080/01605682.2021.1873079
[56] Tang, F. (2020). The more interactivity the better? Investigating interactivity, task complexity, and product knowledge in online purchase decisions. *Information Technology and Management*, pp 1-11, 2020., https://doi.org/10.1007/s10799-020-00316-2
[57] Tang, L., Jang, S. (2008). Tourism information trust as a bridge between information value and satisfaction: An exploratory study. *Tourism Analysis*, 13(5–6), pp 565–578, 2008.
[58] Ugonna, I., A., Okolo, V. O., Nebo, G. N., Ojieze J. (2017). Effects of Online Marketing on the Behaviour of Consumers in Selected Online Companies in Owerri, Imo State – Nigeria. *International Journal of Business and Management Invention*, 6(6), pp 32-43, 2017.
[59] Veleva, S. S.,Tsvetanova, A. I. (2020). Characteristics of the digital marketing advantages and disadvantage. In: IOP Conference Series: Materials Science and Engineering, Volume 940, International Scientific Conference Digital Transformation on Manufacturing, Infrastructure and Service 21-22 November 2019, St. Petersburg
[60] Verma, P., Pant, M. K. (2021). The Effect of Price Verification, Product Display, Assortment Satisfaction upon Overall Satisfaction, Online Repatronage Intention, and Customer Loyalty. *Journal of Food Products Marketing*, 27(6), pp. 291-318, htpps://doi.org/10.1080/10454446.2021.1994078

[61] Walsh, G., Sharon E. B. (2007). Customer-Based Corporate Reputation of a Service Firm: Scale Development and Validation. *Journal of the Academy of Marketing Science*, 35 (1), pp 127-143, 2007.

[62] Yan, Q., Wu, S., Wang, L., Wu, P., Chen, H., & Wei, G. (2016). E-WOM from e-commerce websites and social media : Which will consumers adopt ?. *Electronic Commerce Research and Applications*, 17, pp 62–73, 2016.

[63] Zhou, R., Wang, X., Shi, Y., Zhang, R., Zhang, L., Guo, H. (2019). Measuring e-service quality and its importance to customer satisfaction and loyalty: an empirical study in a telecom setting. *Electronic Commerce Research*, 19, pp 477–499, 2019. https://doi.org/10.1007/s10660-018-9301-3

Preliminary communication / Prethodno priopćenje

WEBSITES AS A SALE CHANNEL FOR CHARTER SERVICES IN NAUTICAL TOURISM

SILVIA GOLEM
University of Split
Faculty of Economics, Business and Tourism
Cvite Fiskovica 5, 21000 Split, Croatia
silvia.golem@efst.hr

MARINA BLAŽEVIĆ
University of Split
Faculty of Economics, Business and Tourism
Cvite Fiskovica 5, 21000 Split, Croatia
mblaze01@live.efst.hr

ABSTRACT

The main aim of this paper is to assess the quality of websites as a sale channel for charter services in nautical tourism. Using the expert evaluation analysis and employing the Web Quality Index (WQI), we select 60 indicators for the website quality, grouped into 4 aspects (communicational, technical, relational and conversional) and 12 parameters. In order to assess their quality, we select ten most visited websites for charter services and analyse their quality. Our results show that the quality differences of the observed websites are mainly due to representation of individual websites features (60 indicators) that affect it. Among the analysed websites, Yacht charter fleet's website proved to have the highest quality index. In general, our finding suggests that providers of charter services should pay attention to the website quality parameters, particularly the technical aspects - website positioning, information usefulness and availability - in the process of the website development.

KEYWORDS: website quality, charter services, expert method

1. INTRODUCTION

The market for charter services, as a part of the nautical tourism industry, is extremely competitive; only well-managed and forward-looking companies which meet and anticipate their customers' needs can survive and thrive. Charter companies mainly operate within tourist destinations, offering and renting a wide range of vessels and nautical services, for the purpose of vacation, recreation and cruising. The leading channel for promotion and sale of the charter services is the Internet. For instance, according to Gračan, Gregorić and Martinić [2016], in Republic of Croatia in 2015, majority of the customers saw and booked the charter services through the Internet.

Charter companies should therefore pay attention to their presence on the Internet, and in particular, to the creation and maintenance of their websites through which they provide information and communicate with potential users. Morrison, Kim and So [2007] emphasize that websites are an important channel through which companies offer directly a large amount of information, and, hence, are becoming an increasingly important tool for marketing and promotion within the tourism industry. Today, this fact is even more pronounced - websites are an extremely important aspect of the business of all actors within the tourism industry. The quality of websites in general, and in the tourism industry in particular, can have a significant effect on the users' purchasing decision and, consequently, on the companies' sales and profits [Lee and Ho, 2007; Morrison, Kim and So, 2007; Law, Qi and Buhalis, 2010; Dworski and Fawzy, 2011; Reed, 2012; Giannakoulopoulos et al., 2019; Lutfie, 2020; Ongsakul et al., 2021; Thongmak, 2022].

Employing a qualitative approach and by engaging three experts in the field, this paper aims to assess the website quality of the world leading charter companies using the Web Quality Index (WQI) assessment method. In particular, experts assessed the occurrence of the sixty quality indicators which, rated and combined together, represent the Web Quality Index for each of the selected websites. Our findings offer valuable insights and policy guidelines for quality managers aiming to improve the website quality, and consequently, success of their companies.

2. WEBSITE QUALITY ASSESSMENT

As pointed by Król and Zdonek [2020], the website quality is particularly broad-ranging and ambiguous and can be analysed in the technical, economic, ergonomic and legal context. In the income-oriented approach, according to Loiacono, Watson and Goodhue [2002], the quality of a website stems from its ability to fulfil users' needs and to encourage them to visit the website again. Many authors [Gretzel and Park, 2007; Gregg and Walczak, 2010; Afshardost et al., 2013; Król and Zdonek [2020], etc.] have attempted to define and describe important characteristics and dimensions of a quality website. Abdallah and Jaleel [2014] classify 15 different models used to assess the website quality across various industries. In the travel and tourism industry they identify six models - Extended Model of Internet Commerce Adoption (eMICA); Modified Balanced Scorecard (mBSC), The Hedonic-Utilitarian Dual Mediation Model, Effectiveness Evaluation Model, Formative Measurement of Website Performance and Web Quality Index (WQI). The letter, for the reasons that are explained in the following section, is used in our analysis.

Not many studies analyze the quality of websites within the nautical tourism sector, for the charter businesses in particular. Benevolo and Spinelli [2018] assess the quality of the 51 tourist ports websites in Italy, using the 2QCV3Q method - a multipurpose tool for qualitative assessment based on experts' assessments. The results suggest that the websites of the investigated tourist ports require significant improvements, and this especially refers to their content and services provided. For instance, the possibilities of e-reservations for berths are very limited; social network management is unsatisfactory, mobile applications for sailors are missing, etc. Furthermore, the study revealed that there is no cooperation or coordination among the examined tourist ports. This lack of cooperation and coordination is quite a detrimental factor, compared to other countries, Croatia for example, where joint access to several ports is a common practice, supporting not only the activities of individual ports, but also the development of the entire country as a destination for nautical tourism. Using the in-depth interview method, Phuaksawat and Nualnim [2010] investigate the most important features of

websites which customers in the UK pay attention to when booking a boat rental online. The following features of websites are found to be the most important, as indicated by the respondents: reliability, insurance services, promptness in responding to inquiries, communication with staff and quality of information. The findings reveal that the most important issue is information accessibility. All respondents indicated that the websites must contain easily accessible information important to them, such as yacht specifications, pictures, prices, etc.. If the relevant information is missing, customers will leave the website without sending an inquiry. Also, the respondents indicate that the previous customers' reviews and opinions were of importance to them, as well as a feeling of "individual attention" from the staff during communication.

3. METHODOLOGY

In order to assess the quality of websites as a sale channel for charter services in nautical tourism and to provide guidelines for their development, we employ the Web Quality Index (WQI) assessment model. Methodologically, this model follows the qualitative scientific approach. More precisely, it involves expert evaluation analysis. In the context of website quality assessment, an expert-based method is more appropriate than a user-based method since the quality of the assessment depends significantly on the expertise of the assessor. The research was conducted in the period June 20 - July 10, 2022.

The first step involves selection of the websites for charter services whose quality will be assessed by the experts. Based on data available from Similar Web - portal which provides data for the performance of various websites, and Tour Scanner - the world's largest portal for searching tours, excursions and tourist activities - the 10 most renowned charter websites were identified; namely, *Click and boat*, *Get my boat*, *Boat setter*, *Yacht Charter Fleet*, *Boat around*, *Zizoo*, *Nautal*, *Sail square*, *Sailo* and *Sam boat*, as presented in Table 1. The main criterion for the websites selection is the number of visits.

Table 1. The ten most visited websites for charter services

Website	Total number of visits (via computer and mobile device) in the last 6 months	Time spent on the website (in minutes per visit)	Number of viewed categories per visit
1. Click and boat	1 610 000	03:30	5.65
2. Get my boat	1 020 000	02:22	5.72
3. Boat setter	863 060	02:08	3.61
4. Yacht charter fleet	360 180	01:33	3.71
5. Boat around	235 980	02:56	3.87
6. Zizoo	209 000	01:59	4.69
7. Nautal	156 280	02:12	3.09
8. Sail square	136 470	04:08	5.26
9. Sailo	128 040	01:36	3.01
10. Sam boat	127 490	03:26	3.50

Source: Authors, based on data provide by Similarweb.com [28.06.2022.]

As demonstrated in Table 1., *Click and boat* website had the largest number of visits (1 610 000), while *Samboat* website was visited 127 490 times. On average, users spent about 4 min per visit on *Sailsquare* website, and only a minute and a half on *Yacht Charter Fleet* website. As for the number of viewed categories per visit, visitors viewed almost 6 categories on *Get my boat* website, and 3 on *Sailo* website. The visitors mostly found the selected websites through the Internet by entering keywords such as: "charter", "sailing", "cruise", etc. in internet browsers, or by typing directly the website, or via social networks. For instance, the majority of users (69.47%) visited *Click and boat* website by entering keywords related to sailing and charter in Internet search engines; 23.13% visited the page directly, while 1.82% of users visited the website via social networks, 1.68% via email, 3.05% of them through advertisements, and 0.85% through the referring sites. Similarly, the second most visited website for charter service, *Get my boat*, was visited mostly through search engines via keywords (63.75%), directly by 26.82% of users, via social networks (4.82%), via e-mail (3.01%), via advertisements (0.13%) and via intermediary sites (1.48%). The fact that the observed websites have such a high proportion of visitors who find them through keywords suggests that these websites well adapted their content to the algorithms of internet search engines and that they offer quality and rich content and a high degree of optimization. A relatively high proportion of visitors who search websites directly suggests that those visitors are customers/existing users who are familiar with the quality of the website or have received a recommendation for the website. Among the observed websites, *Boat around* has the largest share of users who visited it directly (31.53%).

The second step in our assessment procedure is to identify and engage the experts who are willing to participate and provide their expertise. Three experts knowledgeable in the analysed issues are selected to evaluate the quality parameters of the selected websites for charter services. Two experts are web designers, and the third expert is the owner of a travel agency that uses the services of the selected website.

Experts were asked to assess the occurrence of sixty indicators/features of the ten above presented websites for charter services, using a six-point Likert scale ranging from 0 to 5 (where 0 represents absence of feature, 1 stands for poor presence of feature, 2 for moderate presence of feature, 3 reflects acceptable presence of feature, 4 stands for good presence of feature, while 5 represents excellent presence of feature).

The indicators/features are defined based on the relevant literature, and are divided into twelve categories/parameters; namely, *front page, languages, content quantity and quality, usability and availability, web positioning, information structure, social networks, mobile communication, interaction, commercialization, brand, and discourse analysis/ cogency*. Each of the twelve category/parameter contains 5 indicators/features. More precisely, Table 2. shows twelve categories/features with the respective indicators for each parameter.

Table 2. WQI: results

Parameter	*1. Front page*	*2. Languages*	*3. Content quantity and quality*
Indicator	The home page contains features that make it easier to navigate the website	The language used on the website is clear and appropriate	The website provides detailed information about its services
	The content of the home page facilitates further exploration of the website	A tool for automatic translation is available	The information content is rich and diverse
	The home page contains the table of contents and/or website map	It is clear which languages are available on the website	The offered information is regularly updated
	The home page contains tools that increase its efficiency towards the user (e.g. "help", FAQ, search engine, etc.)	Translations correspond grammatically and semantically to the original text (correct spelling and grammar)	Information about popular destinations is easy to find
	The website additionally allows reservation of other tourist-relevant services that can be booked in the form of a package deal	Translation is also available for additional tools and reference materials	The content of the website is clear and easy to understand
Parameter	*4. Usability and availability*	*5. Web positioning*	*6. Information structure*
Indicator	The website is easy to use, i.e. adapted to users' needs	Design suitable for adequate positioning in the Internet search engines (SEO optimization – Lighthouse report)	It is easy to find a specific information and to access all the required information (2-3 clicks to the required information)
	The website is adapted for people with sensory difficulties/disabilities)	The search engine within the website allows searching for keywords	The website is a good source of information on the tourist destination
	It is easy to locate the search browser within the website	The website can be easily accessed through all prominent internet browsers	It is easy to find/research a travel-related information
	The spaces between the text and other elements are constant throughout the website	The internal search results are easy to modify and restart the search	information is provided, organized and structured in a user friendly and convenient format
	Graphics and colour combinations are consistent throughout the website	Search results are clearly presented and automatically sorted by relevance	Navigation through the website is logical and consistent

Parameter	*7. Social networks*	*8. Mobile communication*	*9. Interaction*
Indicator	The possibility of communicating with other users on the website, overview of existing experiences (forum, chat, etc.)	The website is compatible with smartphones	The possibility of interacting with the company via the website (employees e-mails, telephones, online requests, online chat, etc.)
	Ratings, reviews and feedbacks from other users are available	It is easy to buy tourist products/services via smartphone	The website offers information specially adapted to the needs of individual customers (adjustment of various search filters)
	Subscription to news by e-mail (marketing campaigns, promotional offers, etc.) is straightforward	Users can interact and share experiences within the website using a smartphone	There is a possibility of two-way communication between the user and the service provider on the website
	User accounts: personal information, previous purchases and other activities on the website are available	The website is an alternative to calling customer support or the sales department (instant "chat" is offered)	The website contains information about safety, transportation, weather forecast, legal regulations…
	The website is present on social networks	It is easier to use the website than to call customer service	The security protocols are adequately highlighted (security certificate, general privacy policy, info on payment security...)
Parameter	*10. Commercialisation*	*11. Brand*	*12. Discourse analysis/ cogency*
Indicator	Tourist products/services are effectively categorized - all categories are visible and accessible	The website design is creative (innovativeness, creativity and authenticity)	The persuasiveness of the website is manifested through text and images
	The possibility of searching for products/services based on predetermined criteria	The layout of the website is attractive (choice of layout, fonts, colours, etc.)	The website is worth revisiting and sharing with friends
	Integrated reservation system that enables booking of various tourist services	The website is not cluttered with information (effective use of empty spaces)	The images on the website are vivid and provide good visualization of the services
	The special offer feature is visible effectively	The company logo is clear and noticeable on the website	The website is well-informative; it offers information on destination
	Options for distribution of tourist products and services	The company's internet domain is meaningful	The website offers also information on negative aspects of the service

Source: Authors

The experts provided independently a list with their assessments, that is, ratings for all of the sixty indicators/features, divided into twelve quality parameters, for each of the ten websites. Based on their ratings, we determined the website quality index (WQI) for each website. First, we calculated the average rating for each parameter by averaging the ratings of the five indicators which the respective parameter consists of. Second, we determined the website quality index by averaging the ratings of all parameters for a particular website.

4. RESULTS

The results, with the parameter rating and the overall website quality index (WQI) for each website, are given in Table 3. As demonstrated in Table 3., the WQI ranges from 2.31 to 3.26. According to the experts' assessments, the highest WQI is given to *Yacht charter fleet* website. This site, accordingly, can be considered of the highest quality and most suitable website for charter services. *Click and boat*, *Nautal* and *Boat around* seem to be quite close in terms of quality with their WQIs amounting to 3.23, 3.21 and 3.20, respectively. They are followed by *Sail square* (2.93), *Sam boat* (2.67), *Zizoo* (2.58), *Sailo* (2.51) and *Boat setter* (2.45). The lowest ranked website for charter services in our sample is *Get my boat*, with its WQI equal to 2.31.

In this section, we briefly comment on the scores disaggregated by parameters. Overall, the *front page* parameter seems to score poorly, when compared to other quality parameters. In addition, the front page of many websites does not contain or contains inadequately some basic tools, such frequently asked questions, website map or options to book additional services.

Languages score somewhat better, signalling that the websites do pay attention this aspect of quality. Surprisingly, some websites, such as *Get my boat*, *Boat setter* and *Sailo* offer no other language version, except for the English version. *Yacht charter fleet* website offers automatic translation only for the "most important" information, i.e. the service offer, while translation for additional tools and reference materials is unavailable. It seems that the automatic text translation is a website quality aspect that should be improved for all websites in our sample.

As for the *quantity and quality of website's content*, *Yacht charter fleet* website has the higher score; its content that includes useful topics that are beyond the basic charter services. The websites should work to regularly update the content and to offer additional information related to the basic services (for example, information on the destination, gourmet offer, tourist attractions, etc.).

Information *usability and availability* parameter is rated generally poorly for all the selected websites, with *Click and boat* and *Yacht charter fleet*, having the highest rates. The experts' assessments suggest that most websites lack options for people with sensory difficulties.

Website positioning parameter, in general, has the lowest score among all quality parameters, primarily due to the frequent lack of an internal browser, which is found to be a useful tool for users, suggesting that all selected websites should pay more attention to this aspect of quality. This refers especially to *Zizoo* website since it has the lowest score for the website positioning.

Click and boat website has the best rated *information structure*, while *Zizoo* and *Boat around* preform best in the section of *social networks*, thereby offering best opportunities for interaction and information exchange between users. All websites offer direct links to their profiles on social networks at the front page. In general, all websites should put additional effort to improve

the information structure. In particular, the required information should be accessed in just a few clicks by users.

Collectively, among all parameters, the *interaction* parameter has the highest score. Nonetheless, in this category there is a plenty of room for improvements for all websites, especially improving the possibility of direct contact with the service provider (boat renter) and informing users about security protocols that protect them from unwanted events when using the site and shopping service.

Boat around and *Sail square* seem to be the most convenient for *mobile communication*. In general, all observed websites are well adapted to the mobile context. However, mobile versions of certain features such as "instant chat" with customers and "sharing experiences" with other users could be generally improved. *Boat around* also has the highest score for the interaction parameter. It offers many options that make it easier for the customers to use the website.

The *commercialization/marketing* parameter is best developed by *Yacht charter fleet*. The noticeable issue in this category is the lack of an integrated reservation system that enables booking of various tourist services as a bundle. In addition, for majority of websites, the "special offer" option is not noticeable effectively.

Click and boat website is arguably the strongest *brand*, suggested by a numerous highly rated indicators in that area. Most of the observed websites did not have a noticeable "special offer" feature to attract the users' attention, while, for example, *Get my boat* and *Boat setter* sites had a very small selection of basic searching criteria (filters) for specific charter services. The brand parameter is rated highly for most websites. However, some of them, *Sam boat* and *Boat setter* in particular, need to pay more attention to innovation, creativity and authenticity of their design, while *Sam boat, Sail square, Zizoo* and *Yacht charter fleet* should focus more on the visibility of their logo.

As for the *credibility/cogency* parameter, all websites should work more to offer persuasive texts and vivid images that provide the most realistic insight into the offered services. *Click and boat* and *Yacht charter fleet* website have the highest credibility/cogency aspect of quality, as a result of the content quality (persuasiveness of images and text, in particular).

Table 3.: Website quality index: results

Website	Front page	Languages	Content quantity and quality	Usability and availability	Website positioning	Information structure	Social networks	Mobile communication	Interaction	Commercialization	Brand	Discourse analysis	**WQI**
Click and boat	2.2	4	3.8	2.8	1.8	4.2	2.6	3	3.2	2.4	4.8	4	**3.23**
Get my boat	2	0.8	2.2	2.2	2	2.6	2.2	2.4	2.2	2	4.2	3	**2.31**
Boat setter	1.8	1.8	2.2	2.2	1.8	3.6	3	2.2	3.2	2	3.4	2.2	**2.45**
Yacht charter fleet	2.6	1.8	4.4	2.8	4.8	4	2.8	2.6	3.4	3.6	2.4	4	**3.26**
Boat around	2.4	4.2	3.6	2.2	1.6	2.8	3.4	3.6	4.4	3.4	3.6	3.2	**3.2**
Zizoo	3	3	2.8	2.6	1.4	2	3.4	2.8	2.8	1.8	2.8	2.6	**2.58**
Nautal	3.2	4.6	3.6	2.4	1.8	3.8	2.6	3	3.8	3.4	3.4	3	**3.21**

Sail square	2.8	4.2	3.2	2	1.8	3.4	3	3.6	3.2	3.2	2.6	2.2	**2.93**
Sailo	2.8	1.6	2.6	2	1.6	2.4	3	2.8	3.4	2.2	3.4	2.4	**2.51**
Sam boat	3	3	2.4	2	1.8	3	3.2	2	3.8	2.2	2.6	3	**2.67**
Total	**25.8**	**29**	**30.8**	**23.2**	**20.4**	**31.8**	**29.2**	**28**	**33.4**	**26.2**	**33.2**	**29.6**	

Source: Authors

5. CONCLUSION

The main goal of this research is to assess qualitatively ten of the world's most famous and most visited websites for the promotion and sale of charter services, using the expert method approach; in particular, the website quality index method. The experts are asked to evaluate the selected indicators which describe certain features of the individual websites. By combining the ratings of 60 indicators we defined the WQI for each website. The results suggest that *Yacht charter fleet* website has the highest quality index among the observed sites and can be considered the website for the promotion and sale of charter services of the highest quality.

Given that the websites are an essential channel for promotion and sale of charter services, as well as of nautical and other tourism-related services, companies in the respective industries should be concerned with the quality of their websites. By optimizing the existing features of the website and/or by introducing the new ones, they can increase the quality of the website, and, consequently, work towards attaining the best possible business results. Our qualitative analysis demonstrated that charter companies should primarily pay attention to the technical parameters - positioning, usefulness and availability of information - when developing and improving their websites. With the appearance of new innovative features of websites which are out of scope of this research, there appear new prospects to increase the website quality, which may be the subject of future research.

Although our study contributes to the research of the qualitative assessment of the website quality from the expert point of view, there are several limitations that must be acknowledged. The first limitation refers to the qualitative nature of our research which questions the objectivity of our approach and limits the reliability of our results and implications. Also, this study was conducted using a specific set of predetermined indicators for the website quality applied to a specific type of tourism industry, namely, the charter industry. Many recent studies are working to offer relatively objective criteria related to evaluating a website, and it would be useful to compare results based on different approaches to assessing the website quality. Even though further research is required to solidify the results of our study, there is a clear indication that there is a room for the website quality improvements. Our study is of the exploratory nature and the future research calls for more objective approach which includes rigorous quantitative tests of the relationship between the website quality and the company's performance.

REFERENCES

[1] Afshardost, M; Farahmandian, S; SadiqEshaghi, S. M. (2013). Linking Trust, Perceived Website Quality, Privacy Protection, Gender and Online Purchase Intentions. *Journal of Business and Management*,13(4), pp 63-72.

[2] Benevolo, C; Spinelli , R. (2018). The quality of web communication by Italian tourist ports. *Tourism: An International Interdisciplinary Journal*, 66(1), pp 52–62.

[3] Dworski, L; Fawzy, L. (2011). *Emerging Business Online: Global Markets and the*

Power of B2B Internet Marketing, Pearson Education, New York, USA.
[4] Giannakoulopoulos, A.; Konstantinou, N.; Koutsompolis, D.; Pergantis, M.; Varlamis, I. (2019). Academic Excellence, Website Quality, SEO Performance: Is there a Correlation? *Future Internet*, 11, pp 242-267.
[5] Gračan, D; Gregorić, M; Martinić, T. (2016). Nautical tourism in Croatia: current situation and outlook. In *Proceedings of Tourism & Hospitality Industry Congress*, pp 66-79, Opatija, Croatia.
[6] Gregg, D.G; Walczak, S. (2010). The Relationship between Website Quality, Trust and Price Premiums at Online Auctions. *Journal Electronic Commerce Research*, 10(1), pp 1-25.
[7] Gretzel, U; Park, Y. (2007). Success Factors for Destination Marketing Websites: A Qualitative Meta-Analysis, *Journal of Travel Research*, pp 46-63.
[8] Król, K.; Zdonek, D. (2020). Aggregated Indices in Website Quality Assessment. Future Internet, 12, pp 72-84.
[9] Lee, Y. L; Ho, C. L. (2007). The development of an e-travel service quality scale. *Tourism Management*, 28(6), pp 1434-1449.
[10] Lutfie, H. 2020. Effectiveness of Marketing Technology Website Quality On Company Performance and The Impact On Smart Campus Student Satisfaction, Journal of Applied Management (JAM), 18(1), pp. 181-188.
[11] Law, R.; Qi, S.; Buhalis, D. (2010): Progress in Tourism Management: A Review of Website Evaluation in Tourism Research, *Tourism Management*, 31, pp 297-313.
[12] Morrison, A; Kim, D; So, S. (2007). Web-based permission marketing: segmentation for the Lodging industry. *Tourism Management*, 28(6), pp 1408-1416.
[13] Ongsakul, V.; Ali, F.; Wu, C.; Duan, Y.; Cobanoglu, C.; Ryu, K. (2021). Hotel website quality, performance, telepresence and behavioral intentions, *Tourism Review*, 76(3), pp 681-700.
[14] Phuaksawat, C; Nualnim, N. (2010). Customer's selection criteria when booking yacht online, Mälardalen University, Master Thesis.
[15] Reed, J. (2012). Get Up to Speed with Online Marketing: How to Use Websites, Blogs, Social Networking and Much More, Pearson Business.
[16] Thongmak, M. (2022), Website quality and company's market value: an exploration of SMEs and large firms in the Stock Exchange of Thailand, *Measuring Business Excellence*, 26(4), pp 508-523.

Preliminary communication / Prethodno priopćenje

PRIMJENA STABLA ODLUKE NA PROBLEMU IZLASKA PODUZEĆA NA NOVA TRŽIŠTA

TONI CRLJEN
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
tcrljen@student.foi.hr

NIKOLA KADOIĆ
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
nkadoic@foi.unizg.hr

DIJANA OREŠKI
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
dijoresk@foi.unizg,hr

SAŽETAK

Plasiranje proizvoda ili usluga poduzeća na nova tržišta možemo analizirati kao problem odlučivanja u uvjetima nesigurnosti i rizika. Kod izlaska na novo tržište poduzeće treba odlučiti koje je to tržište na koje izlazi. Kad se odluči za tržište, tek dok poduzeće proizvede proizvode ili kreira usluge te razvije kanale prodaje svojih proizvoda ili usluga na tom tržištu, što može predstavljati značajan trošak, poduzeće će vidjeti koliko je izabrano tržište bila dobra odluka - po odgovoru tržišta na ponudu poduzeća. Poduzeće može angažirati odgovarajuću agenciju koja može pomoći u tome da odgovor tržišta bude što bolji. U ovom radu obrađuje se model odlučivanja o izlasku na tržište temeljen na metodi stabla odlučivanja. U studiji slučaja, informatičko poduzeće može samostalno ili uz pomoć specijalizirane agencije izaći na tržište. Korištenje stabla odluke u ovom problemu omogućilo je bolju vizualizaciju bitnih aspekata odluke, racionalni pristup odlučivanju te u konačnici isplativiju odluku. Dodatno, ovakav model odlučivanja može biti dobar promotivni materijal za agenciju koja nudi usluge posredovanja prilikom izlaska na nova tržišta budući da stablo odluke na vizualan i analitički, a opet jednostavan način pokazuje pogodnosti koje nudi agencija u odnosu na samostalni izlazak na tržište.

KLJUČNE RIJEČI: nesigurnost, rizik, posredovanje, izlazak na tržište, stablo odluke

APPLICATION OF DECISION TREE TO THE PROBLEM OF COMPANY EXPANSION INTO NEW MARKETS

ABSTRACT

The placement of a company's products or services in new markets can be analyzed as a decision-making problem in conditions of uncertainty and risk. When entering a new market, the company must decide which market it is entering. After choosing the market and producing products or creating services, as well as developing sales channels for its products or services in that market, which can represent a significant cost, the market will respond to the company's offer (accepting or rejecting the offer). Then the company will see if the decision to choose that market was good or not. The company can hire an appropriate agency that can help ensure a better market response. This paper discusses a decision-making model for market entry based on the decision tree method. In a case study, an IT company can enter the market independently or with the assistance of a specialized agency. The use of a decision tree in this problem enables better visualization of essential decision aspects, a rational approach to decision-making, and ultimately a more profitable decision. Additionally, such a decision-making model can serve as promotional material for an agency offering mediation services for entry into new markets, as the decision tree visually and analytically demonstrates the advantages the agency offers compared to independent market entry.

KEYWORDS: uncertainty, risk, mediation, market-entry, decision tree

1. UVOD

Prvi izlazak poduzeća na neko tržište, kao i novi izlazak poduzeća na tržište novom uslugom ili proizvodom predstavlja problem odlučivanja u uvjetima nesigurnosti i rizika. Izlasku na novo tržište često prethodi detaljna financijska analiza koja uključuje poslovni i marketinški plan izlaska. Velik broj varijabli u tim planovima može se smatrati nesigurnima i pretpostavljenima. Neke od tih varijabli su:

- kvantitativne i kvantificirane kvalitativne varijable pretpostavljene u financijskom planu (npr. cijene režijskih troškova – hoće li doista biti onakve kako smo ih obračunali u financijskom planu, ili je moguće da će neki neželjeni događaj (ili željeni događaj) utjecati na značajno povećanje (ili smanjenje) režijskih troškova),
- reakcija tržišta (hoće li potražnja za proizvodima i/ili uslugama s kojima se izlazi na nova tržišta biti u skladu s pretpostavkama u financijskom planu),
- odgovor tržišta na kontramjere definirane u analizi rizika (ukoliko je potražnja za proizvodima ili uslugama s kojima se izlazi na novo tržište niska te potom poduzmemo odgovarajuće dodatne mjere za povećanje potražnje sukladno matrici rizika u marketinškom planu, hoće li te mjere doista uspjeti i povećati potražnju),
- možebitna promjena zakonske regulative, i sl.

Većina ovih varijabli su i međusobno povezane i njihovoj analizi je moguće pristupiti mrežnim putem, nakon čega je moguće primijeniti metode poput različitih metoda za višekriterijsko odlučivanje koje podržavaju modeliranje mreže (Kadoić, 2018; Michnik, 2013; Saaty, 2008), ili metode kao što je analiza društvenih mreža (Knoke & Yang, 2008). Njihovom primjenom, među svim nesigurnim varijablama, možemo identificirati najnesigurnije varijable. Dodatno,

prilikom izlaska na nova tržišta, osim ovih metoda, uključujući i metode odlučivanja u uvjetima nesigurnosti i rizika, svakako je oportuno primijeniti metode analize osjetljivosti.

U ovom radu bavimo se primjenom metode stabla odluke (jedne od složenijih metoda u području odlučivanja u uvjetima nesigurnosti i rizika, (Sikavica i ostali, 2014)) u problemu izlaska na nova tržišta na studiji slučaja jedne hrvatske agencije. Navedena agencija se bavi razvojem poslovanja za različite klijente, s fokusom na plasiranje na nova tržišta koristeći različite platforme i društvene mreže. Ova primjena napravljena je s pozicije klijenata – poduzeća koje želi izaći na novo tržište, a koja taj izlazak može napraviti samostalno, vlastitim resursima, ili uz pomoć spomenute hrvatske agencije koja se bavi razvojem poslovanja. U tom smislu, identificirane su nesigurne varijable i one su modelirane u stablu odluke. Osim toga, stablo odluke je upotpunjeno dodatnim jednovarijabilnim i dvovarijabilnim analizama osjetljivosti koje su primijenjene s ciljem potvrde inicijalnog prijedloga odluke od strane stabla odluke. Konačno, ovakav model, koji koristi stablo odluke, može biti i promotivni materijal za hrvatsku agenciju koja nudi usluge posredovanja prilikom izlaska na nova tržišta, budući da model sadrži varijable i stvarne podatke koje opisuju uspješnost posredovanja agencije, kao i podatke koji opisuju uspješnost izlaska na nova tržišta ukoliko se ono radi samostalno od potencijalnog klijenta. Vrijedi i spomenuti da postoji i druga istoimena metoda – stablo odluke (ili stablo odlučivanja) – iz područja rudarenja podataka. Te dvije metode su različite, no, postoje i sličnosti među njima, kao i pokušaji njihovih primjena u jednom hibridnom modelu (Kadoić i ostali, 2021).

Ovaj rad je organiziran na sljedeći način: Sekcija 2 sadrži opis primijenjene metodologije u ovoj analizi poslovnog slučaja. Sekcija 3 prikazuje detaljni opis problema izlaska poduzeća na novo tržište. Sekcija 4 prikazuje rezultate primjene metoda stabla odlučivanja i analize osjetljivosti u poslovnom slučaju. U sekciji 5 prezentirani su konačni zaključci analize i pregled mogućih nastavaka ovog istraživanja.

2. METODOLOGIJA ISTRAŽIVANJA

Ovo istraživanje je po svojoj vrsti analiza poslovnog slučaja, a kao epistemiološki pristup korišten je pragmatizam. Za analizu poslovnog slučaja i postizanje ciljeva istraživanja korištene su dvije metode: stablo odluke i analiza osjetljivosti. Prije njihove prezentacije navodimo osnovne ciljeve istraživanja.

Ciljevi istraživanja su:

1. Istražiti mogućnosti primjene stabla odluke i analize osjetljivosti u problemu izlaska na nova tržišta.
2. Istražiti mogućnosti korištenja modela stabla odluke i analize osjetljivosti u problemu izlaska na nova tržišta za promotivne potrebe agencija koje se bave posredovanjem prilikom izlaska na nova tržišta.

2.1. STABLO ODLUKE

Stablo odluke je jedna od najsloženijih metoda iz skupine metoda odlučivanja u uvjetima nesigurnosti i rizika (Schultz i ostali, 2010). Ova skupina metoda uključuje (1) jednostavne kriterije za odlučivanje u uvjetima nesigurnosti, u što ubrajamo Waldov kriterij (maxmin kriterij, ziheraški pristup, pesimistični pristup), maxmax kriterij (optimistični pristup, riskirajući pristup), Hurvitzov kriterij realizma te Savageov kriterij minimalnog žaljenja, te (2)

metode za odlučivanje u uvjetima rizika, što uključuje Laplaceov kriterij, kriterij očekivane vrijednosti, pravilo (EV, δ), Bernoullijevo pravilo, stablo odluke te matricu rizika (Taha, 2017; Yan i ostali, 2021; Yoe, 2019). Ono što stablo odluke kao metodu čini složenijom od drugih nabrojanih jest što se u jednom modelu odlučivanja može modelirati veći broj odluka i događaja, a ne samo po jedan, kao što je to u slučaju drugih metoda (ne računajući matricu rizika) (Dionisio, 2018).

Stablo odluke je grafička metoda (Maseer & Flayyih, 2021). Pri tome se koriste grafičke oznake i simboli nabrojani u nastavku. Stablo odluke crta se s lijeva na desno, a smjer crtanja elemenata stabla prati vremenski tijek događanja u konkretnom problemu odlučivanja. Stablo odluke se sastoji od glavnog čvora koji predstavlja donošenje odluke, skupa srednjih čvorova (događaja) koji predstavljaju određenu vrstu neizvjesnosti te čvorova posljedica koji predstavljaju moguće konačne ishode. Uobičajeno je dodjeljivanje vjerojatnosnih distribucija u obliku težina u čvorovima događaja kako bi se mjerila povezana neizvjesnost. Osnovni elementi stabla odlučivanja su (Ekenberg i ostali, 2006):

- Čvorovi odluke (grafički se prikazuje kvadratićem),
- Grane alternativnih aktivnosti (grafički se prikazuju linijom, pri čemu se naziv grane piše iznad linije, poravnato lijevo),
- Čvorovi mogućih posljedica (grafički se prikazuje kružićem),
- Grane mogućih posljedičnih stanja (grafički se prikazuju linijom, pri čemu se naziv grane piše iznad linije, poravnato lijevo),
- Trošak ili prihod akcije alternative ili posljedičnih stanja (iznos troška ili prihoda veže se uz svaku pojedinu granu alternativnih aktivnosti, kao i granu mogućih posljedičnih stanja i najčešće se piše ispod grane, poravnato lijevo),
- Vjerojatnosti pojave mogućih stanja (vjerojatnost izražena kao decimalni broj ili razlomak, najčešće se prikazuje iznad grane mogućih posljedičnih stanja iznad grane, poravnato desno),
- Završni čvorovi (grafički se najčešće prikazuju trokutićem, završni čvorovi predstavljaju završetak grananja stabla odluke),
- Vrijednosti konačne isplate financijske koristi (vežemo ih uz završne čvorove i iznosi se upisuju desno od završnih čvorova; vrijednosti se računaju tako da se zbroje/oduzmu svi prihodi i troškovi od korijena stabla na putu do završnog čvora).

Koraci u metodi stabla odluke su sljedeći (Damghani i ostali, 2009):

1. Crtanje grafičkog i logičkog modela stabla odluke pretvarajući tekstualne podatke u pripadajuće čvorove odluka, čvorove događaja te završne čvorove. Nakon toga je potrebno provjeriti stablo odluke kako bismo bili sigurni da su uključeni svi mogući ishodi. Također, unutar ovog koraka, računaju se i vrijednosti završnih čvorova.
2. Izračunavanje očekivanih vrijednosti svake grane polazeći s desne prema lijevoj strani, (primjena *rollback* algoritma). Očekivane vrijednosti grana najčešće se prikazuju ispod grane, poravnato desno. Pri tome:
    a. očekivane vrijednosti završnih grana jednake su vrijednostima završnih čvorava,
    b. očekivane vrijednosti grana iza kojih je čvor događaja računaju se po formuli za matematičko očekivanje, $EV_{i-1} = \sum_{j=1}^{n} p_{ij} EV_j$ (suma produkata vjerojatnosti grana koje izlaze iz čvora događaja i njihovih očekivanih vrijednosti),
    c. očekivane vrijednosti grana iza kojih je čvor odluke određuje se kao najveća od svih očekivanih vrijednosti grana koje izlaze iz čvora odluke.
3. Posljednji korak je pronalaženje optimalnog puta, točnije grana koje nam donose najveću korist.

Metoda stablo odluke može se primijeniti ručno, ili uz podršku računala. Najpoznatiji alati za podršku metodi stabla odluke su TreePlan, PrecisionTree i Silverdecisions.

Prikaz 1. Primjer jednostavnog stabla odluke

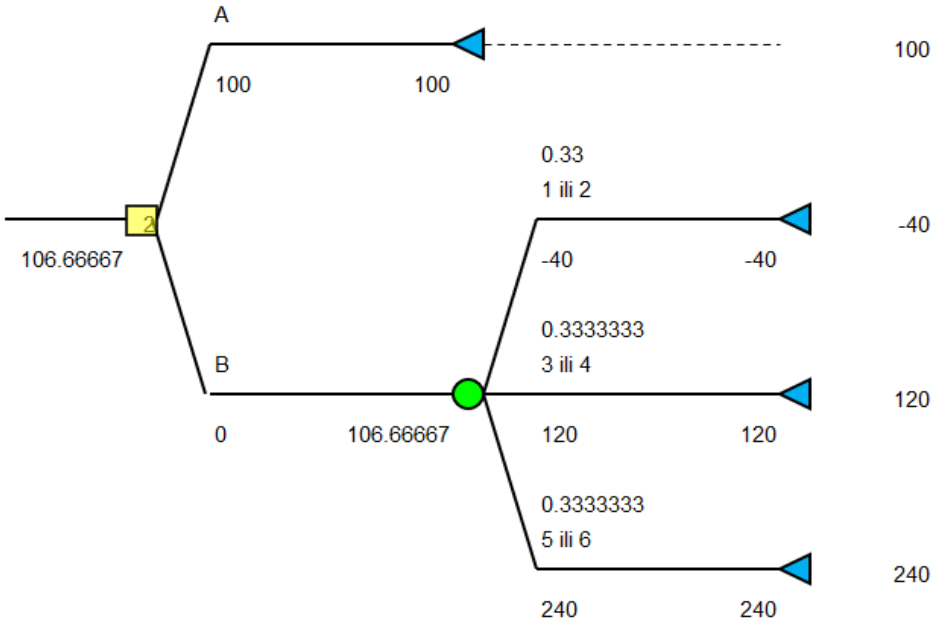

Izvor: Autori

Prikaz 1 predstavlja primjer jednostavnog stabla odluke kreiranog u alatu TreePlan. Igraču su ponuđene dvije igre. Igra A da igrač dobiva 100 eura (bez ikakve poduzete akcije). U slučaju da se odluči za igru B, u kojoj je potrebno da igrač baci kocku, pravila igre su sljedeća: (1) igrač osvaja 240 eura u slučaju da dobije brojeve pet ili šest; (2) igrač osvaja 120 eura u slučaju da dobije brojeve tri ili četiri; (3) igrač gubi 40 dolara u slučaju da dobije brojeve jedan ili dva. Na prikazu su označeni i izračunati svi elementi i očekivane vrijednosti u skladu s prethodnim teorijskim opisom stabla odluke. Optimalni put u ovom problemu jest izabrati igru B.

Važno je istaknuti da je sam proces razmišljanja koji prati izradu stabla jednako vrijedan kao i samo stablo. Taj proces potiče donositelja odluke da razmisli o budućem planu, koji se sažima kroz točke grananja gdje donositelj odluke može utjecati na smjer kojim se ide ili gdje se mogu pojaviti slučajni događaji. Stablo odlučivanja može se koristiti u različitim područjima, uključujući poslovanje, financije, zdravstvo i analizu podataka. Posebno su korisna kada odluke uključuju višestruko povezane izbore i neizvjesnosti. Analiza stabla odlučivanja omogućuje pojedincima ili grupama sistematsku analizu složenih scenarija odlučivanja, usporedbu različitih alternativa i procjenu potencijalnih rizika i nagrada svake opcije. Korištenjem metode stabla odlučivanja u donošenju odluka, pojedinci ili grupe mogu sistematski analizirati i vrednovati složene odluke, razmotriti više faktora i potencijalne ishode te donositi informirane odluke na temelju relevantnih informacija (Sarkar, 2012).

2.2. ANALIZA OSJETLJIVOSTI

Analiza osjetljivosti jest metoda kojom ispitujemo kako se mijenja neka zavisna (izlazna) varijabla (ili više njih) temeljem promjene jedne ili više nezavisnih (ulaznih varijabli). Radi se o generičkoj metodi koja se može primijeniti svugdje gdje postoji pretvorba nekog ulaza u izlaz (Saltelli i ostali, 2004). Tako ju možemo nadovezati i na stablo odluke i primjerice promatrati kako će se mijenjati konačna odluka u Prikazu 1, odluka između A i B, ako se mijenja prihod

koji će se ostvariti ukoliko igrač pri bacanju kocke ostvari 5 ili 6 – trenutno je 240 eura, no možemo se pitati što će biti ako će taj prihod biti manji, ali i: do koliko smije biti taj prihod manji da je i dalje isplativo igrati B).

Tri su osnovne vrste analize osjetljivosti:

1. Jednovarijabilna analiza osjetljivosti – analiza promjene jedne izlazne varijable ako se mijenja jedna ulazna varijabla. Grafički se ovakva analiza može prikazati kroz linijski graf, a u MS Excelu se ovakva analiza može primijeniti korištenjem opcije *Data table*,
2. Dvovarijabilna analiza osjetljivosti – analiza promjene jedne izlazne varijable ako se mijenjaju dvije ulazne varijable. Grafički se ovakva analiza može prikazati kroz histogram, a u MS Excelu se ovakva analiza može primijeniti korištenjem opcije *Data table,*
3. Viševarijabla analiza osjetljivosti – analiza promjene jedne izlazne varijable ako se mijenjaju tri ili više ulazne varijable. Grafički se ovakva analiza može prikazati kroz *tornado* i *spider* grafove, a u MS Excelu se ovakva analiza može primijeniti korištenjem dodatka *Sensit*.

Analitički dio ovog istraživanja izrađen je u alatu TreePlan i u MS Excelu.

3. STUDIJA SLUČAJA: IZLAZAK PODUZEĆA NA NOVA TRŽIŠTA

Jedna hrvatska agencija bavi se razvojem poslovanja za različite klijente, s fokusom na plasiranje na nova tržišta koristeći različite platforme. Kao što je ranije spomenuto, analiza će biti odrađena iz perspektive klijenta (poduzeća koje namjerava izaći na novo tržište), koji bi u ovom slučaju birao između ponude agencije i samostalnog izlaska na tržište. Poduzeću kojem su ponuđene usluge posredovanja bavi se web developmentom i specijaliziran je u izradi kompleksnih sustava, bez međunarodnog iskustva. Poduzeće sadrži stručni tim iskusnih programera, dizajnera i inženjera te klijentima pruža usluge dizajna i razvoja visoko prilagođenih web aplikacija. Poduzeće želi izaći na jedno od tri nova tržišta: skandinavsko, anglosaksonsko ili balkansko tržište, a taj proces može izvesti samostalno ili uz posredovanje agencije. Dodatno, dok se izlazi na neko tržište, kampanja izlaska se može izvesti na jedan od dva načina. Kod kraće kampanje (kampanja 1) je početni odaziv bolji jer se klijente opterećuje s manje informacija i veći je fokus na dovođenje tih klijenata "za stol", kako bi se odradio sastanak s njima. Opširnija kampanja (kampanja 2) uključuje detaljnije informacije i temeljitiji sadržaj koji će se prezentirati klijentima u porukama, što u početku dovodi do manjeg broja pozitivnih odgovora jer sami klijenti nemaju naviku prolaziti kroz sadržaj toliko detaljno i ignoriraju poruke ili odbijaju sam poziv za sastanak. Kod opširnije kampanje klijenti koji prođu detaljno kroz sadržaj i odluče se pristupiti sastanku, upućeniji su u usluge navedenog poduzeća i dolaze na sastanke s konkretnim potrebama i idejom. S druge strane, kod skraćene kampanje konačni broj održanih sastanaka je veći, ali sami klijenti dolaze s više nesigurnosti i neodlučnosti zbog nedovoljne upućenosti u usluge poduzeća i konačan broj ostvarenih ugovora je nešto manji nego u usporedbi s opširnijom kampanjom.

U suštini, poduzeće treba izabrati jednu od dvije opcije:

1. Ponuda agencije za usluge plasiranja na tržišta je sljedeća (2600 eura):
    a. Faza pripreme u trajanju od dva tjedna koja uključuje istraživanje tržišta, filtriranje i odabir idealnih poduzeća kojima će se nuditi usluga, radionice na temu odabira ciljne grupe, pristup klijentima i odabir kampanje. Cijena ovog dijela iznosi 350 eura. Ovaj dio troška je kod agencije dosta nizak, što u samostalnom izlasku na

tržište neće biti slučaj. Razlog tome je što agencija ima postojeće baze podataka koje samo treba filtrirati na temelju usluga koje poduzeće nudi, uz moguća dodatna, kratka istraživanja. Također, po pitanju kampanja agencija ima ideju i plan na koji način će se slagati kampanje, iz iskustva s prethodnim klijentima. Točnije, zna na što treba obratiti pozornost za pojedinu platformu.

b. Nakon odrađene pripreme slijedi kreiranje potrebnih računa za platforme koje će se koristiti i kontaktiranje potencijalnih klijenata, koje će trajati tri mjeseca. Cijena iznosi 750 eura mjesečno (ukupno 2250 eura). U cijenu su uključene moguće izmjene ciljane grupe, modificiranje sadržaja i izmjene strategije te dnevno vođenje, vođenje kampanja, praćenje odgovora od strane klijenata, kreiranje potrebnih izvještaja, povremenih sastanaka između agencije i poduzeća, troškovi licenci i praćenje kampanja s povremenim kreiranjem izvještaja o progresu. Kroz tri mjeseca poduzeće će imati na raspolaganju agenta, s kojim će biti u stalnom kontaktu zbog provjere klijenata, dogovora oko termina sastanaka i ostalih izvještaja.

2. Samostalni izlazak na tržište (2070 eura). Temeljem stvarnih iskustava, u ovom scenariju bi vremenski okviri bili nešto drugačiji. S obzirom na to da je poduzeće do sad bilo fokusirano na domaće tržište i nemaju iskustva izlaska na vanjska tržišta, određeni elementi pripreme iziskivat će nešto više vremena nego kod agencije. Također, kvaliteta sadržaja koja će se prezentirati stranim klijentima je upitna jer opet, nemaju prijašnjeg iskustva sa sličnim. Trošak satnice rada na ovim aktivnostima iznosi 12 eura:
   a. Krenuti ćemo od istraživanja tržišta. Procjena je da bi bilo potrebno pedesetak sati utrošenog vremena za adekvatno istraživanje tržišta i pronalaska optimalne grupe klijenata. Naravno, procjena ovisi o sposobnostima i iskustvu zaduženih za istraživanje, pa samim time može varirati. Možemo reći da ova procjena naginje prema donjoj granici potrebnih sati za istraživanje. Treba uzeti u obzir da je potrebno provesti određeno vrijeme na upoznavanje s alatima pomoću kojih bi se vršilo istraživanje tržišta, tek onda krenuti u istraživanje. Ukupni trošak aktivnosti 50 sati po 12 eura iznosi 600 eura.
   b. Slaganje kampanja je sljedeći trošak koji traje 20 sati. Kvaliteta sadržaja koja se prezentira potencijalnim kupcima je svakako stavka koja se ne smije zanemariti, s obzirom na to da je to prvi niz informacija o uslugama poduzeća koje se prezentiraju klijentima. U slučaju loše prezentacije sadržaja kampanje, velik broj potencijalnih klijenata otpada u startu. Trošak aktivnosti je 240 eura.
   c. Dolazimo do dijela koji uzima najviše vremena (80 sati). Ona uključuje vođenje računa na platformama, praćenje rezultata u smislu odgovora klijenata, njihovo filtriranje, izradu potrebnih izvještaja, konzultacije s nadležnima vezane za napredak i slično. Ova stavka se na prvu čini lako izvedivom, ali potreban je kvalitetan angažman za sve navedene korake. U slučaju da je zaposlenik zadužen za veći broj poslova i ne može adekvatno voditi račune i pratiti razgovore s klijentima, lako je preskočiti ili zaboraviti odgovoriti potencijalnom klijentu te ostaviti neprofesionalan dojam prije nego što je uopće došlo do sastanaka. Tu uvijek postoji i opcija da klijent ostane nezadovoljan procesom komunikacije i odustane od sastanka. Ukupni trošak aktivnosti 960 eura.
   d. Posljednja stavka je trošak licenci i iznosi 270 eura kroz period od tri mjeseca.

Ukupni trošak druge opcije dvadesetak je posto manji od troška prve opcije, no ova analiza ne uključuje varijable koje opisuju uspješnost svake od dviju alternative, temeljem dosadašnje statistike (Tablica 1). Dodatno, ulazne varijable (npr. satnica od 12 eura) je potencijal za primjenu analize osjetljivosti.

Tablica 1. Uspješnost izlaska na tržište – posredovanjem agencije i samostalno

Tržište	Kampanja	**Vjerojatnost da je ostvaren pozitivan odgovor**		**Vjerojatnost da je ostvaren ugovor**	
		Agencija	**Samostalno**	**Agencija**	**Samostalno**
Skandinavsko tržište	1	0.4	0.3	0.35	0.35
	2	0.35	0.25	0.4	0.4
Anglosaksonsko tržište	1	0.4	0.3	0.3	0.3
	2	0.35	0.25	0.35	0.35
Balkansko tržište	1	0.45	0.35	0.2	0.2
	2	0.4	0.3	0.25	0.25

Izvor: Autori

4. REZULTATI

Zbog veličine, cijelo stablo odluka nije prikazano. Prikaz 2 predstavlja strukturu jedne grane u stablu odluke za slučaj dok se poduzeće odluči za posredovanje agencije i izlazi na skandinavsko tržište. Na slici vidimo (s lijeva na desno) da nakon što se odabere skandinavsko tržište, slijedi biranje između vrste kampanje (kraća ili opširnija). Potom slijedi događaj koji pokazuje da li je ostvaren pozitivan ili negativan odgovor. Ovdje se vidi prva razlika između dviju kampanja, gdje je kod skraćene kampanje vjerojatnost pozitivnih odgovora nešto veća. Nakon pozitivnih odgovora slijede nove dvije grane koje sadrže jedan završni čvor i jedan čvor odluke. Ovi čvorovi uzimaju u obzir broj pozitivnih odgovora koji su doveli do sastanka s čelnicima poduzeća i potencijalnim klijentima, te gledaju omjer ostvarenih ugovora iz tih sastanaka. Prilikom ostvarenja ugovora dolazimo do dobiti od četrdeset tisuća eura. Ovdje primjećujemo razliku u drugoj, proširenoj verziji kampanje da je broj ostvarenih ugovora veći, iz razloga spomenutih ranije. Iz grane neostvarenih ugovora slijedi čvor odluke, koji nam daje dvije alternative, a to je promjena tržišta ili odustajanje, točnije ostanak pri trenutnom odabiru. Struktura drugih stabla odluke identična je ovoj strukturi, samo se mijenjaju nazivi tržišta te vjerojatnosti sukladno podacima iz Tablice 1. Tako imamo još 2 ovakve grane u slučaju posredovanja agencije (za slučaj anglosaksonskog i balkanskog tržišta) te 3 grane za sva tri tržišta u slučaju samostalnog izlaska na tržište.

Rezultati pokazuju da je u slučaju posredovanja agencije ostvarena očekivana vrijednost 3000 eura i da je najbolje orijentirati se na skandinavsko tržište. I u samostalnom izlasku na tržište najbolje je orijentirati se na skandinavsko tržište, no ovaj put je ostvarena očekivana vrijednost 2802 eura, iz čega možemo zaključiti da je posredovanje agencije uspješnije u odnosu na samostalni izlazak.

Prikaz 2. Struktura grane odabira skandinavskog tržišta u slučaju posredovanja agencije

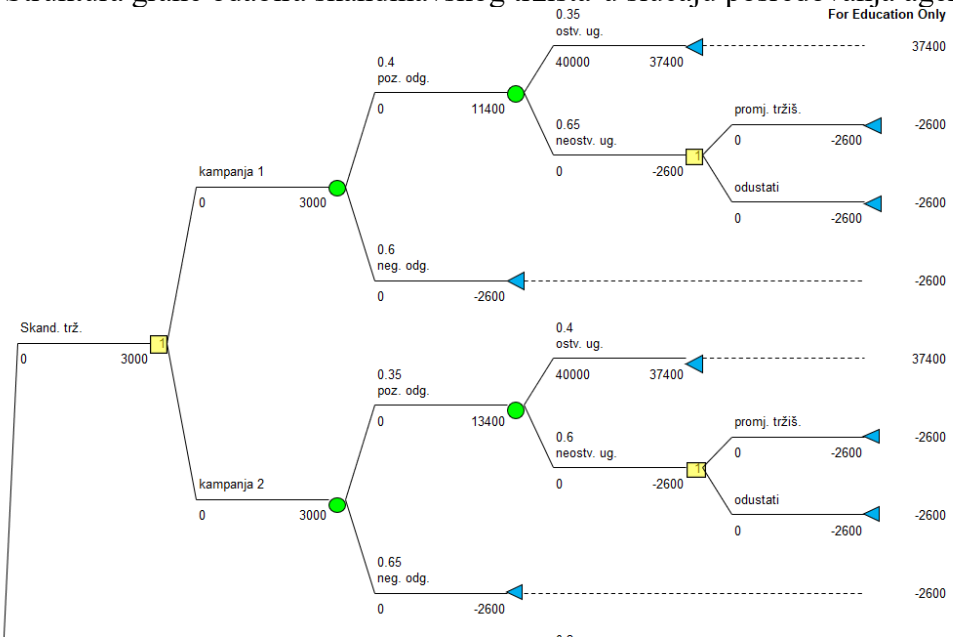

Izvor: Autori

Preostaje nam odraditi i analizu osjetljivosti kako bismo utvrdili koliko je odluka o posredovanju agencije bolja od samostalnog izlaska na tržište. Prvo ćemo odraditi ranije najavljenu jednovarijabilnu analizu osjetljivosti utjecaja cijene sata kod samostalnog izlaska na tržište na konačnu odluku o odabiru načina izlaska na tržište. Tablica 2 prikazuje konačnu odluku s obzirom na satnicu koja se kreće u intervalu od 9 do 15 eura.

Tablica 2. Jednovarijabilna analiza osjetljivosti troška satnice na način izlaska na tržište

Satnica	**Odluka**
9	Samostalno
10	Agencija
11	Agencija
12	Agencija
13	Agencija
14	Agencija
15	Agencija

Izvor: Autori

Iz Tablice 2 vidimo kako bi u scenariju da satnica padne ispod deset eura, odluka pala na samostalan izlazak na tržište. To je naravno malo izgledno s obzirom da poduzeće nema dovoljno velik marketinški tim, i teško bi uklopilo cijeli proces bez dodatnog angažmana. Kada bi se dogodio scenarij u kojem bi vlasnik poduzeća odlučio dodatno opteretiti zaposlenike bez adekvatne isplate, subjektivno je mišljenje da bi se takav prihod preslikao na kvalitetu ostalih elemenata izlaska na tržište, te bi druge brojke u stablu odlučivanja patile. Iz tog razloga ćemo pretpostaviti da vlasnik poduzeća primjereno plaća svoje radnike, te ćemo se zadržati na navedenim brojkama, koje lako mogu biti i veće. Dodatno, satnica od 9 eura u praktičnom smislu znači da je mjesečna neto plaća zaposlenika oko 1000 eura, što je teško slučaj u informatičkim tvrtkama. Dodatno, prema Tablici 1 vidimo razlike u vjerojatnostima za pozitivan odgovor u slučaju posredovanja agencije i kod samostalnog izlaska na tržište. Upravo to je temelj za provođenje dodatnih 6 dvovarijabilnih analiza osjetljivosti (svaka od 6 vjerojatnosti iz Tablice 1 (4. stupac) – u intervalu od 0.3 do 0.45 - bit će kombinirana sa

satnicom koja se kreće u intervalu 9-15). Prikaz 3 prikazuje histogram frekvencija konačnih odluka po 168 različitih scenarija obuhvaćenih u 6 dvovarijabilnih analiza osjetljivosti. Zaključujemo da u velikoj većini slučajeva, odluka pada na angažiranje agencije da posreduje u izlasku na tržište. Odluka o samostalnom izlasku uglavnom se odnosi na ranije analiziranu situaciju sa pomalo nerealno niskom satnicom od 9 eura.

Prikaz 3. Histogram konačnih odluka u analizama osjetljivosti

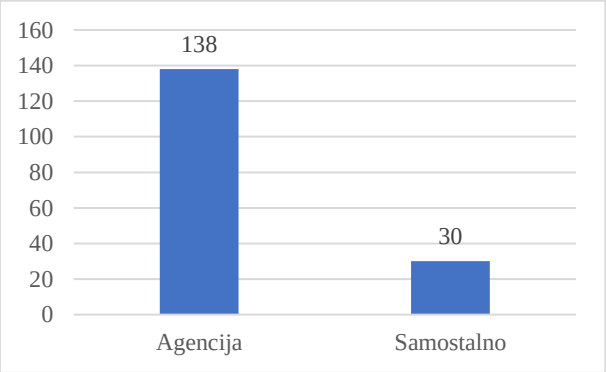

Izvor: Autori

Kada bi podaci iz Tablice 2 i Prikaza 3 bili takvi da jedna alternativa tako snažno ne dominira nad preostalima, bilo bi potrebno poduzeti dodatne analize.

5. ZAKLJUČAK

U ovom radu analizirali smo mogućnosti primjene metode stabla odluke u kombinaciji s analizom osjetljivosti u kontekstu odlučivanja o izlasku na nova tržišta. Ovim radom smo pokazali da se metoda stabla odluke u kombinaciji s analizom osjetljivosti vrlo uspješno može primijeniti u analizi problema odlučivanja o izlasku na nova tržišta čime je postignuti prvi cilj istraživanja. U radu smo pokazali primjenu metode stabla odluke za grafički prikaz scenarija odlučivanja i za donošenje odluke u inicijalnom modelu odlučivanja. S obzirom na nesigurne varijable u modelu, provođenjem analize osjetljivosti dodatno se provjerava stabilnost inicijalne odluke. U našem slučaju je odluka prilično stabilna. Nestabilne situacije su one kada ne postoji tako snažna dominacija jedne alternative nad drugima i tada donošenje odluke zahtijeva dodatne analize. Vezano uz drugi cilj istraživanja, u slučaju da neka agencija želi koristiti konkretne rezultate primjene metoda kao što su to prikazi 2 i 3 te Tablica 2, svakako to i može budući da krajnji rezultati zorno, na jednostavan i razumljiv način, prikazuju prednosti posredovanja agencije u ovom problemu odlučivanja.

Nastavak ovog istraživanja vidimo u primjeni Bayesovog teorema prilikom analiza vjerojatnosti u Tablici 1 (zadnja dva stupca).

ZAHVALA

Ovaj rad je podržala Hrvatska zaklada za znanost preko projekta UIP-2020-02-6312. Ovaj rad rezultat je rada i istraživanja prilikom izrade završnog rada studenta Tonija Crljena na stručnom studiju Sveučilišta u Zagrebu Fakulteta organizacije i informatike, pod nazivom *Primjena metode stablo odlučivanja u poslovnom okruženju* (mentor: doc.dr.sc. Nikola Kadoić; suocjenjivačica: izv. prof.dr.sc. Dijana Oreški).

REFERENCE

[1] Damghani, K. K., Taghavifard, M. T., & Moghaddam, R. T. (2009). Decision Making Under Uncertain and Risky Situations. *Enterprise Risk Management Symposium Monograph Society of Actuaries - Schaumburg*, *148*. http://www.ermsymposium.org/2009/pdf/2009-damghani-decision.pdf

[2] Dionisio, C. S. (2018). *A Project Manager's Book of Tools and Techniques* (1st editio). John Wiley & Sons Inc.

[3] Ekenberg, L., Danielson, M., & Thorbiörnson, J. (2006). Multiplicative properties in evaluation of decision trees. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, *14*(03), 293–316. https://doi.org/10.1142/S0218488506004023

[4] Kadoić, N. (2018). *Nova metoda za analizu složenih problema odlučivanja temeljena na analitičkom mrežnom procesu i analizi društvenih mreža*. University of Zagreb.

[5] Kadoić, N., Oreški, D., & Lendl, M. (2021). Comparative analysis of decision tree methods from two scientific fields. U Z. J. Drobne S., Zadnik Stirn L., Kljajic Borstnar M., Povh J. (Ur.), *Proceedings of the 16th International Symposium on Operational Research in Slovenia, SOR 2021* (str. 683–690). Operational Research Society.

[6] Knoke, D., & Yang, S. (2008). *Social network analysis, Second Edition*.

[7] Maseer, R. W., & Flayyih, H. H. (2021). A Suggested Approach to Use a Decision Tree to Rationalize the Decision of Accounting Information Users under the Risk and Uncertainty. *Studies of Applied Economics*, *39*(11). https://doi.org/10.25115/eea.v39i11.5877

[8] Michnik, J. (2013). Weighted influence non-linear gauge system (WINGS)-An analysis method for the systems of interrelated components. *European Journal of Operational Research*, *228*(3), 536–544. https://doi.org/10.1016/j.ejor.2013.02.007

[9] Saaty, T. L. (2008). The Analytic Hierarchy and Analytic Network Measurement Processes: Applications to Decisions under Risk. *European journal of pure and applied mathematics*, *1*(1), 122–196. https://doi.org/10.1007/978-3-540-92828-7_4

[10] Saltelli, A., Tarantola, S., Campolongo, F., & Ratto, M. (2004). *Sensitivity analysis in practice: A guide to assessing scientific models*.

[11] Sarkar, D. (2012). Decision tree analysis for project risk mitigation options for underground metro rail project. *International Journal of Decision Sciences, Risk and Management*, *4*(1/2), 25. https://doi.org/10.1504/IJDSRM.2012.046613

[12] Schultz, M. T., Mitchell, K. N., Harper, B. K., & Bridges, T. S. (2010). Decision Making Under Uncertainty Engineer Research and Development Decision Making Under Uncertainty. *Engineer Research and Development Center*, *November*.

[13] Sikavica, P., Hunjak, T., Begičević Ređep, N., & Hernaus, T. (2014). *Poslovno odlučivanje*. Školska knjiga.

[14] Taha, H. A. (2017). *Operations Research An Introduction* (M. J. Horton (ur.); Tenth Edit). Pearson Education Limited. http://zalamsyah.staff.unja.ac.id/wp-content/uploads/sites/286/2019/11/9-Operations-Research-An-Introduction-10th-Ed.-Hamdy-A-Taha.pdf

[15] Yan, X., Madjidov, S., Halepoto, H., & Ikram, M. (2021). Developing a Framework for the Optimization Processes of Logistics Costs: A Hurwitz Criterion Approach. *SAGE Open*, *11*(4), 215824402110544. https://doi.org/10.1177/21582440211054499

[16] Yoe, C. (2019). *Principles of Risk Analysis*. CRC Press. https://doi.org/10.1201/9780429021121

Preliminary communication / Prethodno priopćenje

ISKUSTVA I STAVOVI HRVATSKIH POTROŠAČA O PRIMJENI PROŠIRENE STVARNOSTI PRILIKOM ONLINE KUPOVINE

ANA KARLICA
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
akarlica@student.foi.hr

DIJANA PLANTAK VUKOVAC
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
dijana.plantak@foi.unizg.hr

SAŽETAK

Proširena stvarnost jedna je od tehnologija koja je u posljednjih nekoliko godina postala dostupna krajnjem korisniku, naročito uz primjenu (web) kamere na računalu ili mobitelu. Ova tehnologija omogućuje da se računalno generirani objekti dodaju stvarnom okruženju korisnika pa korisnik percipira virtualne objekte kao da su dio fizičkog svijeta. U kontekstu prikaza nekog proizvoda, proširena stvarnost omogućuje dodatne informacije o proizvodu u realnom vremenu i 3D prostoru, što korisniku može olakšati donošenje odluke o kupovini. Kupac primjenom proširene stvarnosti može npr. na svom mobitelu vidjeti kako će mu stajati neki odjevni predmet ili kako će se komad namještaja uklopiti u njegovu sobu, prije nego se odluči na online kupovinu ili odlazak u fizičku trgovinu.

Dosad provedena istraživanja ukazuju na pozitivan utjecaj korištenja proširene stvarnosti u maloprodaji. S jedne strane proširena stvarnost utječe na povećanje stope konverzije, a s druge strane korištenje AR-a je zabavno i smanjuje neizvjesnost kupaca kod online kupovine.

U anketnom istraživanju koje je provedeno željela se utvrditi primjena proširene stvarnosti u online trgovinama iz perspektive hrvatskih potrošača. U radu će biti prikazani rezultati istraživanja o upoznatosti hrvatskih potrošača s proširenom stvarnošću općenito i njihovom mišljenju o primjeni iste u online trgovinama. Također će se predstaviti iskustva i ponašanja potrošača vezanih uz korištenje AR tehnologije u online kupovini.

KLJUČNE RIJEČI: proširena stvarnost, online trgovina, online kupovina, potrošači, anketa

EXPERIENCES AND ATTITUDES OF CROATIAN CONSUMERS REGARDING THE USE OF AUGMENTED REALITY IN ONLINE SHOPPING

ABSTRACT

Augmented reality is one of the technologies that has become available to end-users in recent years, especially with the use of a (web) camera on a computer or mobile phone. This technology allows computer-generated objects to be added to the user's real environment, so the user perceives virtual objects as if they were part of the physical world. In the context of displaying a product, augmented reality provides additional real-time and 3D spatial information about the product, which can facilitate the user's decision-making process when it comes to making a purchase. By using augmented reality, a consumer, for example, can see on his/her mobile device how a piece of clothing will look on him/her or how a piece of furniture will fit into his/her room before deciding to make an online purchase or visit a physical store.

Previous research indicates a positive impact of augmented reality use in retail. On one hand, augmented reality contributes to an increase in conversion rates, and on the other hand, the use of AR is entertaining and reduces customer uncertainty in online shopping.
In the survey conducted, the goal was to determine the use of augmented reality in online stores from the perspective of Croatian consumers. The paper will present the results of the research regarding the awareness of Croatian consumers about augmented reality in general and their opinions on its application in online stores. Additionally, the experiences and behaviors of consumers related to the use of AR technology in online shopping will be presented.

KEYWORDS: augmented reality, online store, online shopping, consumers, survey

1. UVOD

U posljednjih nekoliko godina, pod utjecajem različitih faktora iniciranih razvojem tehnologije, pa sve do pandemije koronavirusa koja je zadesila svijet, u potpunosti se promijenio doživljaj ljudi diljem svijeta o važnosti kupovine, načinima kupovine i kanalima kroz koje se ta kupovina može odvijati. Također se iz istih razloga pojavio i pojačan interes potrošača prema online kupovini i njenim koristima koje su zbog svoje jednostavnosti, dostupnosti i brzine korištenja postale sve važnijim elementom, a moglo bi se čak i reći i osnovnom potrebom, u ljudskim životima i njihovoj svakodnevici [Shaw, Eschenbrenner, Baier, 2022]. Osim klasične online kupovine, zamah su dobile i različite tehnologije kao što su virtualna stvarnost, proširena stvarnost, Metaverzum, te umjetna inteligencija, čime naš život sve više ulazi u sferu prividnog. Proširena stvarnost (eng. *Augmented Reality*, AR) jedna je od tehnologija koja ima za cilj spojiti najbolje od oba svijeta – stvarnost i virtualnost. Ta tehnologija, ima mogućnost integriranja u različite aspekte ljudskog života u svrhu njegova obogaćenja i poboljšanja doživljaja stvarnosti kroz dodavanje digitalnih elemenata [Khan, 2023].

Danas je proširena stvarnost prerasla u tehnologiju koja je postala dostupna krajnjem korisniku, naročito uz primjenu web kamere na računalu odnosno kamere na mobitelu. Korištenjem mobilne aplikacije koja omogućuje proširenu stvarnost i kroz usmjeravanje kamere svog mobitela prema nekom objektu, korisnik može na zaslonu mobitela dobiti dodatne tekstualne

ili vizualne informacije o tom objektu, npr. prilikom šetnje nekim turističkim mjestom, može uz AR aplikaciju na zaslonu mobitela dobiti dodatne informacije o ulici kojom šeće ili turističkoj atrakciji koju promatra [‘Augmented Reality for Travel and Tourism Industry | Zeal AR’, 2021]. Također, korisnik može u prostor koji ga okružuje, uz korištenje mobilne aplikacije podržane AR-om, ubaciti neki virtualni element, npr. parkirati računalno generirani Porsche u svoje dvorište ili dodati 3D objekt planeta Marsa s dodatnim informacijama i zanimljivostima o planetu [Genetic Engineering & Biotechnology News, 2021].

U kontekstu prikaza nekog proizvoda u online trgovini, proširena stvarnost omogućuje dodatne informacije o proizvodu u realnom vremenu i 3D prostoru, što korisniku može olakšati donošenje odluke o kupovini. Ovu funkcionalnost proširene stvarnosti u značajnoj mjeri koriste modna i kozmetička industrija pa omogućuju svojim kupcima npr. isprobavanje odjeće, naočala ili ruža za usne iz udobnosti svog doma, pri čemu se stvarna osoba tj. sam kupac koristi kao model i prikazuje na ekranu, a kupac uz svoj lik na ekranu vidi dodatan sloj (npr. odjeće ili ruža za usne) koji se prilagodio građi i konturama samog kupca. Dosadašnja istraživanja provedena u svijetu ukazala su na mnoge prednosti korištenja proširene stvarnosti u online trgovini, no istraživanja u Hrvatskoj, prema saznanjima autorica, većinom su se bavila percepcijom AR-a u marketingu, a nisu se bavila utvrđivanjem primjene AR tehnologije u online kupovini.

U ovom radu, uz pregled nekoliko istraživanja, bit će prikazani rezultati vlastitog anketnog istraživanja o upoznatosti hrvatskih potrošača s proširenom stvarnošću općenito i njihovom mišljenju o primjeni iste u online trgovinama. Također će se predstaviti iskustva i ponašanja potrošača vezana uz korištenje AR tehnologije u online kupovini.

2. KARAKTERISTIKE PROŠIRENE STVARNOSTI

Proširena stvarnost opisuje se kao vrsta tehnologije kroz koju je omogućena integracija trenutne računalno generirane informacije u svakodnevni svijet korisnika, odnosno kroz koju je omogućeno kreiranje poboljšane verzije ljudske stvarnosti uz mogućnost upotrebe tekstualnih, vizualnih, zvučnih, 3D i ostalih elemenata [Microsoft Dynamics 365, bez dat.; Chen et al., 2019]. Ona ustvari povećava osjećaj realnosti postavljanjem sloja s virtualnim objektima na stvarni svijet u stvarnom vremenu [Carmigniani i Furth, 2011] te pruža dodatno znanje o stvarnom svijetu.

Tri su osnovne karakteristike proširene stvarnosti: a) kombiniranje informacija iz stvarnog i digitalnog okruženja, b) interakcija ostvarena u stvarnom vremenu, te c) međusobno usklađivanje virtualnih i stvarnih objekata u 3D prostoru. [Microsoft Dynamics 365, bez dat.; Tacgin, 2020]. Da bi se proširena stvarnost pretočila u stvarni svijet potrebna je upotreba uređaja kao što su pametni telefoni ili tableti s ugrađenom kamerom, web kamere osobnih računala ili laptopa, ili naglavni AR zaslon odnosno AR naočale poput Google Lenses ili najnovijeg Apple Vision Proa.

Proširena stvarnosti vrlo se često mijenja ili čak poistovjećuje s drugim tehnologijama, poput virtualne stvarnosti (VR), mješovite stvarnosti (MR) i produžene stvarnosti (XR). Prema [Moore, 2023] proširena stvarnost od virtualne razlikuje po tome što ona u obzir uzima pravu ljudsku stvarnost i u nju dodaje generirane računalne elemente, dok je virtualna stvarnost kompletno računalno generirana i doima se „stvarno“ samo zbog upotrebe za to prikladnih uređaja. Također, AR predstavlja dio mješovite stvarnosti ili se gleda kao njen produžetak, a razlika je u tome što proširena stvarnost u ljudsko okruženje dodaje slojeve informacija bez

mogućnosti interakcije tih dvaju elemenata, dok mješovita stvarnost omogućuje interakciju digitalnih i stvarnih elemenata uključujući korisnika kao posrednika između njih [Tremosa, 2023; BasuMallick, 2022]. Produžena stvarnost predstavlja krovni termin za kombinaciju ljudske stvarnosti, proširene stvarnosti, virtualne stvarnosti i svih mogućih tehnologija koje mogu nastati kombinacijom dvije ili više od svih dosad spomenutih [Tremosa, 2023].

2.1. TEHNOLOŠKA POZADINA PROŠIRENE STVARNOSTI

Proširena stvarnost sastavljena je od pet ključnih elemenata, a to su: umjetna inteligencija s ulogom olakšavanja rada proširene stvarnosti, AR softver koji je glavni pokretač tehnologije, procesi operacijskog sustava uređaja, leće za kvalitetan prikaz sadržaja i senzori za detekciju vanjskih podražaja [Microsoft Dynamics 365, bez dat.] Sve navedene komponente, bile one fizičkog ili digitalnog karaktera, namijenjene su da olakšaju mapiranje područja oko korisnika koji koristi proširenu stvarnost putem svog uređaja, i da mjere udaljenost između senzora u uređaju i površine/objekta gdje se želi projicirati proširena stvarnost [Sarvaiya, 2019; GeoSLAM, bez dat.]. Osim toga, te komponente ključne su za ostvarenje interakcije između uređaja, korisnika i informacija u stvarnom svijetu kroz superimpozicijske efekte. Sve navedeno obično se ostvaruje kroz naglavne uređaje koji omogućuju prikaz zaslona na naočalama/kacigi, kroz prikaz na ručnom zaslonu (pametni telefon ili tablet) te uređaje koji omogućuju prikaz proširene stvarnosti na zaslonu monitora računala [Chen et al., 2019].

2.2. VRSTE PROŠIRENE STVARNOSTI

Osnovna podjela proširene stvarnosti vrši se prema markeru, pa razlikujemo AR temeljen na markeru (*Marker-based AR*) i AR bez markera (*Makerles-based AR*). Marker predstavlja okidač, npr. sliku ili QR kod, kojeg prepoznaje kamera na mobitelu ili tabletu te pokreće digitalni AR sadržaj na uređaju [Dilmegani, 2023; Digital Promise, bez dat.; Tagcin, 2020]. Tipičan primjer su AR knjige koje sadrže sliku kao okidač za prikaz dodatnog digitalnog sadržaja na zaslonu uređaja.

Druga vrsta AR-a je ona bez markera koja za pokretanje aplikacija proširene stvarnosti detektira podražaje iz okruženja korisnika, npr. lokaciju, pokrete, oblike ili objekte, korištenjem optičkih, mehaničkih, magnetskih, ultrasoničnih ili GPS sustava za praćenje koji sadrže potrebne senzore [Tagcin, 2020]. Nakon detektiranja, uključuje se simultana lokalizacija i mapiranje, tzv. SLAM algoritam, za mapiranje i tumačenje okolnog 3D okruženja. Zatim se pojavljuje AR sadržaj koji se uklapa u fizički svijet i može promatrati iz bilo kojeg položaja ili kuta [GeoSLAM, bez dat.; Nextech, 2022]. Najpoznatiji primjeri proširene stvarnosti bez markera su igra PokemonGO unutar koje korisnici love Pokemone u svojoj okolini i aplikacija Ikea Place koja u dom korisnika postavlja željeni namještaj [Peel X, 2023; Webwise, bez dat.].

3. POSTOJEĆA ISTRAŽIVANJA O PROŠIRENOJ STVARNOSTI

3.1. PRIMJENA PROŠIRENE STVARNOSTI U RAZLIČITIM INDUSTRIJAMA

Prema podacima Statiste (2023a) predviđa se da će prihod u sektoru AR oglašavanja doseći 4,30 milijardi američkih dolara u 2023. godini te da će prosječna godišnja stopa rasta između 2023. i 2027. iznositi 11,81%, što bi trebalo rezultirati i tržišnim volumenom od 6,72 milijardi američkih dolara u 2027. Za kraj 2023., za zajedničko tržište AR i VR očekuje se prihod u

iznosu od 31,12 milijardi američkih dolara i prosječna godišnja stopa rasta od 13,72% te tržišni volumen od 52,05 milijardi američkih dolara [Statista, 2023b].

Prema zajedničkom istraživanju Deloitte i Snapchata [2021] predviđa se da će do 2025. godine gotovo 75% ukupne svjetske populacije biti čestim korisnikom proširene stvarnosti. Točnije, da će se raditi o 4,3 milijarde korisnika, pri čemu će najveći dio činiti *Milenijalci* i *Generacija Z,* a manji dio *Generacija X* i *Boomeri*. Također je utvrđeno kako 73% ispitanika uspješno može identificirati AR kad vide primjer, ali da im je teško definirati što je to. Za njih 65% se utvrdilo da koriste AR u svrhu zabave i da većina njih zna za AR zbog društvenih mreža. Uz to, pokazalo se kako se AR generalno i dalje doživljava kao „igračka“, ali 76% ispitanika smatra da se može koristiti u praktične svrhe. Istraživanje je pokazalo da korištenje AR prilikom kupnje ima stopu konverzije u iznosu od 94%. Nadalje, istraživanjem se utvrdilo da će se kupci (njih 41%) prije odlučiti za kupnju proizvoda nekog branda ako poduzeće koristi AR te da većina njih (56% ispitanika) ima veće povjerenje u kvalitetu proizvoda [Snapchat, 2021].

U praktičnoj upotrebi, osim u igrama, proširena stvarnost se pokazala pouzdanim alatom u medicini i edukaciji. Dokaz tome je uvođenje proširene stvarnosti u učionice mnogih škola, a primjer je viša škola Episcopal Baton Rouge u Los Angelesu u kojoj AR služi kao pomoć pri boljem razumijevanju nastavnog materijala o ljudskom tijelu i svemiru. Iz škole su potvrdili kako se nakon određenog broja provedenih eksperimenta utvrdilo da je AR pozitivno utjecala na učenje i olakšala razumijevanje kompleksnih tema [Episcopal School of Baton Rouge, 2021]. Istraživanje provedeno u medicinske svrhe ticalo se sustava Endosight kako bi se testirala mogućnost korištenja proširene stvarnosti u kompleksnim onkološkim zahvatima. Željelo se utvrditi kako AR utječe na korištenje operacijskih igli u procesu koji uključuje tumore u imaginarnim pacijentima uz istovremenu vizualizaciju tumora. Rezultati su pokazali precizniju upotrebu igala pri onkološkim zahvatima, smanjenje nepotrebnog izlaganja pacijenta ionizirajućem zračenju te se omogućila lakša vizualizacija organa na tabletu i na pacijentu bez upotrebe različitih medicinskih uređaja [Solbiati, Passera, Rotilio, Oliva, Marre, Goldberg, Ierace, Solbiati, 2018].

3.2. PRIMJENA PROŠIRENE STVARNOSTI U PRODAJI

U razvijenom svijetu utjecaj proširene stvarnosti na prodaju istražuje se već nekoliko godina, pri čemu su u istraživanjima naročito zastupljeni istraživači azijskog tržišta. Primjerice, zasebna istraživanja autora Tan, Chandukala i Reddy (2021) i autorice Yoo (2023) analizirala su utjecaj AR-a na prodaju proizvoda na tržištu Azija-Pacifik i na ponašanje potrošačica prilikom online kupnje u AR aplikaciji LoLoZem na južnokorejskom tržištu. Njihovi zasebni rezultati su pokazali pozitivan utjecaj AR-a na prodaju proizvoda, posebice za manje poznate marke i specijalizirane proizvode te da proširena stvarnosti ima veći utjecaj na prodaju skupljih proizvoda zbog mogućnosti smanjenja neizvjesnosti pri kupnji. Utvrdilo se uz to kako cijena proizvoda ima negativan utjecaj na prodaju, bez obzira na korištenje proširene stvarnosti. Istraživanjem [Tan et al., 2021] također se željelo istražiti kako prethodna iskustva kupaca s online kupnjom utječu na upotrebu AR-a i prodaju, zbog čega se utvrdilo da AR ima veći utjecaj na kupce koji tek otkrivaju neku kategoriju proizvoda. Autorica Yoo (2023) također otkriva da se stopa konverzije utrostručila kad se koristila aplikacija LoLoZem, što je dokazalo i popularnost i stabilnost aplikacije. Nadalje, istraživanjem je potvrđeno kako su kvaliteta medija i interaktivnost pozitivno povezane s teleprisutnosti te utječu na utilitarne i hedonističke vrijednosti, što dalje utječe na ponašanje i namjeru kupaca. Također, utvrdilo se da je upotreba AR-a učinila proces kupnje zanimljivim i zabavnim, potičući potrošačice na ponovnu kupnju i preporuku aplikacije obitelji i prijateljima.

Istraživanja hrvatskih autora ponajprije se odnose na istraživanja percepcije proširene stvarnosti u marketingu općenito, odnosno u nekom elementu marketinškog spleta, i većim su dijelom provedena u okviru izrade završnih ili diplomskih radova, a ovdje se izabralo jedno koje će se ukratko opisati. Tako je autorica Nađ (2021) u svom diplomskom radu u sklopu svog istraživanja nastojala utvrditi opće poznavanje značenja AR i VR među ispitanicima te dobiti uvid u njihove stavove prilikom upotrebe istih u marketinške svrhe. Istraživanje je provela nad studentima Ekonomskog fakulteta u Osijeku (46 ispitanika), a rezultati su pokazali kako su ispitanici uglavnom čuli za proširenu i virtualnu stvarnost, ali većina ih još nije koristila ili su koristili u maloj mjeri kroz godinu. Isto tako, istraživanje je potvrdilo da AR i VR pozitivno utječu na marketinške aktivnosti te da daju bolje informacije o proizvodima što olakšava odluku o kupnji. Međutim, istraživanje je otkrilo kako većina studenata ne razlikuje ova dva pojma tj. često ih zamjenjuju.

4. METODOLOGIJA ISTRAŽIVANJA

Kako bi se saznalo koliko hrvatski potrošači poznaju te u kojoj mjeri koriste proširenu stvarnost i druge tehnologije povezane s tim pojmom, provedeno je anketno istraživanje kojim se ispitalo znanje potrošača o različitim vrstama tehnologija, ali primarno o proširenoj stvarnosti s naglaskom na njeno korištenje u procesu online kupovine. Cjelovito istraživanje opisano je u radu [Karlica, 2023], a ovdje su predstavljeni izdvojeni rezultati vezani uz stavove i primjenu proširene stvarnosti u online trgovinama iz perspektive hrvatskih potrošača.

Istraživačka pitanja na koja se odgovara u ovom radu su sljedeća:

A) Kakva su iskustva hrvatskih potrošača u korištenju proširene stvarnosti prilikom online kupovine?

B) Koji su stavovi hrvatskih potrošača o primjeni proširene stvarnosti u online kupovini?

Kako bi se dobili odgovori na postavljena pitanja provedeno je anketno istraživanje tijekom srpnja i kolovoza 2023. godine u ukupnom trajanju od mjesec dana. Anketni upitnik sastojao se od 42 pitanja, od kojih se šest njih odnosilo na demografske podatke ispitanika. Jedna sekcija s pitanjima odnosila se na upoznatost ispitanika s novim tehnologijama, uključujući proširenu stvarnost. U sljedeće dvije sekcije ispitivalo se iskustvo ispitanika s online kupovinom i korištenjem AR-om tijekom iste te stavovi ispitanika o online kupovini i AR-u. Većina pitanja bila je zatvorenog tipa kod kojih su se odgovori birali na Likertovoj skali od 1 do 5. Anketni upitnik bio je izrađen u obliku Google obrasca.

Za kreiranje uzorka ispitanika koristila se metoda snježne grude, pri čemu se krenulo s pet osoba koje su dalje proslijedile poveznicu na anketni upitnik putem raznih Facebook i Instagram profila, te privatnih Messenger grupa.

5. REZULTATI ANKETNOG ISTRAŽIVANJA

5.1. DEMOGRAFSKE KARAKTERISTIKE ISPITANIKA

Prigodni uzorak ispitanika sastojao se od ukupno 135 ispitanika od kojih je 89 ili 65,9% bilo ženskog spola, dok je njih 46 tj. 43,1 % bilo muškog spola. Prema dobi, najveći broj ispitanika (66 ili 48,9%) bio je starosti između 23 i 26 godina, a slijede ispitanici starosti od 20 do 23

godine (24 ili 17,8%). Manji broj ispitanika bio je između 30 i 35 godina (8 ili 5,9%), zatim u dobi od 17 do 20 godina (7 ili 5,2%) ili od 35 do 40 godina (4 ili 3%). Bilo je po četvero ili 3% starijih ispitanika u dobi od 45 do 50 i od 50 do 55. Troje ispitanika ili 2,2% bilo je u dobnoj skupini od 40 do 55 godina, a jedan ispitanik bio je stariji od 65 godina.

Prema razini obrazovanja većina ispitanika ili 73,3% bila je visokoobrazovana (58 ili 43% ispitanika prvostupnika, 38 ili 28,1% magistara te dva ispitanika s doktoratom znanosti i jedan sa završenim poslijediplomskim specijalističkim studijem). Preko 76% ispitanika je zaposleno i otprilike su jednoliko distribuirani (23,7%-22,2%) prema ekonomskim sektorima: u tercijarnom sektoru (trgovina i razne usluge), kvartarnom sektoru (školstvo, zdravstvo, uprava itd.) i kvintalnom sektoru (informatička djelatnost). Manji broj ispitanika radi u sekundarnom sektoru (industrija, energetika, građevinarstvo...), a jedan ispitanik je spadao u primarni sektor.

Ispitanici su bili iz 17 županija, s najvećim brojem ispitanika iz Varaždinske županije (41,5%), a slijede Grad Zagreb (14,8%), Koprivničko-križevačka županija (11,9%) i Međimurska županija (6,7%).

5.2. ISKUSTVA ISPITANIKA S PROŠIRENOM STVARNOŠĆU U ONLINE KUPOVINI

Prije pitanja o iskustvima s proširenom stvarnošću u online kupovini, postavljena su pitanja o upoznatosti ispitanika s terminom proširene stvarnosti. Od 135 ispitanika, njih 89 ili 65,9% odgovorilo je da je upoznato s tim terminom, njih 26 (19,3%) je čulo za termin proširena stvarnost, no nisu sigurni što to točno znači, a 20 ispitanika ili 14,8% odgovorilo je da nisu čuli za proširenu stvarnost.

Dodatno, željelo se utvrditi na koji su način ispitanici prvi puta čuli ili iskusili AR. Najveći broj ispitanika čuo je ili isprobao AR kroz društvene mreže (66 ili 48,9%) te videoigre (51 ili 37,8%). Ostali su čuli ili isprobali AR u školi/na fakultetu ili na praksi odnosno poslu, što je s ostalim odgovorima predstavljeno u Prikazu 1.

Prikaz 1. Način na koji su ispitanici čuli ili iskusili proširenu stvarnost

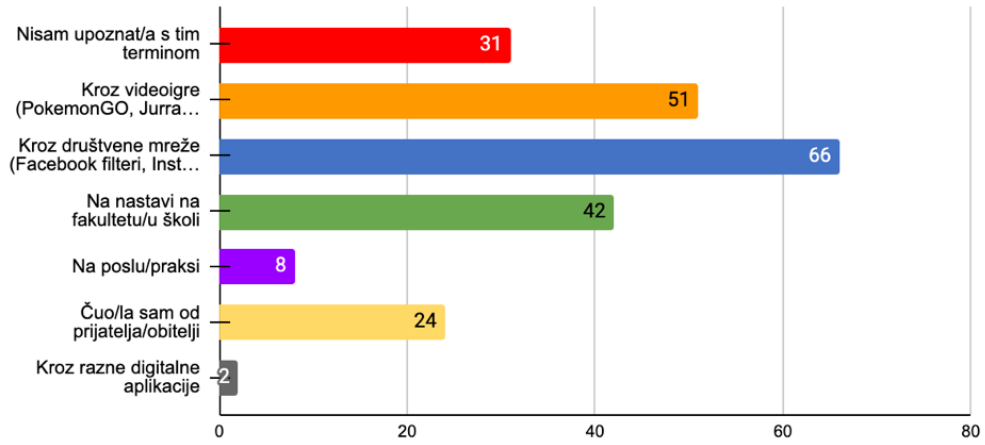

Izvor: Autorice

Izlučno pitanje kojim se željelo utvrditi stvarno korištenje proširene stvarnosti glasilo je: "Koliko dugo koristite aplikacije proširene stvarnosti?". Od 135 ispitanika njih 80 ili 59,3%

odgovorilo je da još nisu koristili aplikacije proširene stvarnosti. Od ostalih 55 ispitanika koje je koristilo AR aplikacije, najviše njih (18 ili 13,3%) koristilo je AR više od 3 godine, a slijede oni koji su koristili AR manje od 6 mjeseci (11 ili 8,1%).

Sljedeći skup pitanja ispitivao je opća iskustva ispitanika s online trgovinom. Velika većina ispitanika (110 ili 81,5%) koristila je online trgovinu (vidi Prikaz 2), pri čemu se gotovo polovica ispitanika (54 ili 49,1%) za pristupanje online trgovini češće služi mobilnim uređajem (pametnim telefonom ili tabletom), oko 31% ili 34 ispitanika češće koristi računalo, dok 20% ili 22 ispitanika podjednako koriste obje opcije.

Prikaz 2. Korištenje online trgovine i način pristupa online trgovini

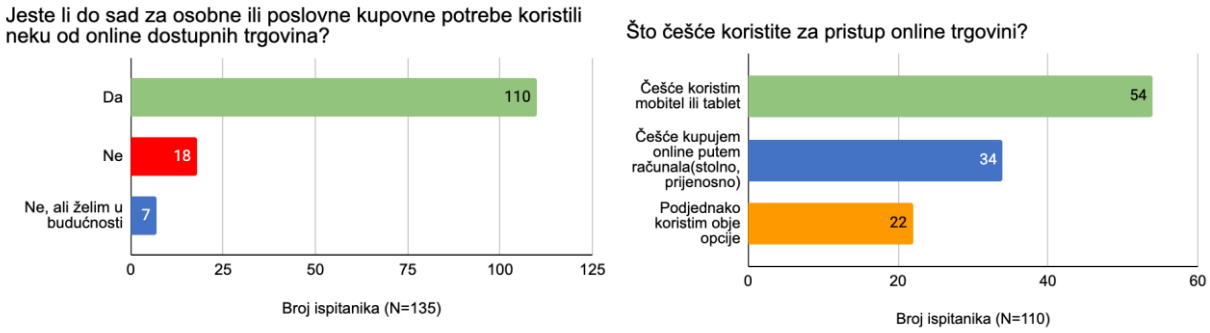

Izvor: Autorice

Najveći dio ispitanika ponekad instalira mobilnu aplikaciju online trgovine na svoje računalo ili mobilni uređaj (41 ispitanika ili 37,3%). Gotovo uvijek instalira mobilnu aplikaciju trgovine 30 ispitanika ili 27,3%, a manjina nema običaj (28 ili 25,5%) ili uopće ne instalira (11 ili 10%) mobilnu aplikaciju.

Iako preko 80% ispitanika koristi online trgovinu, iskustvo s proširenom stvarnošću među ispitanicima bilo je zastupljeno u značajno manjoj mjeri. Samo 31 ispitanik ili 28,2% odgovorio je da je koristio mobilnu aplikaciju ili web stranicu online trgovine koja omogućava isprobavanje proizvoda ili usluga kroz proširenu stvarnost. Ukupno 65 ispitanika ili 59,1% nema takvo iskustvo, dok je 14 njih ili 12,7% odgovorilo da nije sigurno. Potonje dvije kategorije ispitanika nakon toga su odgovarali na općenita pitanja koja se povezana sa stavovima o proširenoj stvarnosti i online trgovini i predstavljena su u sljedećem poglavlju.

Od 31 ispitanika koji su koristili AR u online trgovini, najveći broj ispitanika s takvim iskustvom bile su žene (21 ili 67,7%). Ispitanici su koristili razne AR aplikacije, a kao jedna od kategorija aplikacija bila je ponuđena moda (odjeća, obuća, kozmetika). Kako je dio ispitanika naveo naziv online trgovine za AR isprobavanje naočala, ta je kategorija izdvojena iz mode te se uparivanjem odgovora ispitanika u kategoriji AR aplikacije s nazivom aplikacije, došlo do rezultata koji su prikazani u Tablici 1. Upravo je isprobavanje naočala pomoću AR-a bilo bilo najzastupljenije kod ispitanika.

Neki ispitanici detaljno su objasnili korištenje AR aplikacije:

> *Jednom prilikom putem Nike web stranice isprobala sam funkciju proširene stvarnosti kako bi vidjela koji model i broj tenisica mi najbolje odgovara. Odabrala sam model tenisice koji mi se najviše sviđao i skenirala stopalo kako bi vidjela kako bi mi tenisice pristajale te ujedno koji je odgovarajući broj koji bih trebala naručiti.* (Ž, dob 23-26, kategorija Moda)

ViewRanger, aplikacija dizajnirana posebno za avanturiste koji traže sjajnu stazu kojom bi krenuli u avanturu. (M, dob 30-35, kategorija Videoigre)

Web trgovina adrialece.hr nudi mogućnost isprobavanja okvira dioptrijskih i sunčanih naočala, potrebno je upaliti kameru na uređaju i otprilike se može vidjeti kako bi pojedini okviri odgovarali licu kupca. (Ž, dob 23-25, kategorija Naočale)

Tablica 1. Kategorije i primjeri online trgovina s AR funkcijom

Kategorija	**N**	**% ispitanika**	**Primjeri online trgovina s AR funkcijom**
Moda	6	19,4%	DermaCare, Fenty Beauty, AboutYou, Nike
Naočale	21	67,74%	Adrialeće, Optika Anda, ZenniOptical, Eyerim
Videoigre	4	12,94%	PS Store, ViewRanger
Namještaj	6	19,4%	IKEA, Lesnina
Automobil	3	9,7%	Auto konfigurator na skoda.hr
Arhitektura/dizajn	1	3,2%	nije naveden primjer
Računala	1	3,2%	AliBaba, Amazon

Izvor: Autorice

Nakon toga, ispitanici su se izjašnjavali o iskustvu korištenja online trgovine s AR funkcijom. Čak 74,2% ispitanika (njih 23) navela su da im je bilo jednostavno ili iznimno jednostavno koristiti AR funkciju unutar online trgovine. Dijelu ispitanika (25,8% ili 8) nije bilo niti jednostavno niti komplicirano, a nitko se nije izjasnio o kompliciranom korištenju AR funkcije. Uz to, 71% ili 22 ispitanika bili su zadovoljni ili iznimno zadovoljni dodatnim informacijama o proizvodu koji su dobili kroz korištenje proširene stvarnosti, dok je 29% ili 9 ispitanika bilo neutralno po tom pitanju. Također, isti broj ispitanika (71% ili 22) smatra da mu je korištenje proširene stvarnosti u online trgovini pomoglo u odabiru i donošenju konačne odluke o kupnji, dok je neutralno bilo 25,8% ili 8 ispitanika, a samo je jedan ispitanik utvrdio da mu AR uopće nije pomogla u kupnji.

U nastavku, 31 ispitanik je odgovorio o svom dojmu o online trgovini i njenom ponovnom korištenju, što je prikazano u Prikazu 3. Dojam koji je ostavila proširena stvarnost u online trgovini je pozitivan, tj. poboljšan ili u potpunosti poboljšan za 71% ispitanika. Više od polovice ispitanika ponovno je koristilo istu online trgovinu s AR-om, a 48,4% je označilo da će možda ponovno koristiti istu online trgovinu s AR-om.

Temeljem tog iskustva, 50% ispitanika preporučilo je online trgovinu (aplikaciju ili na webu) koja omogućuje isprobavanje proizvoda ili usluga kroz proširenu stvarnost članovima svoje obitelji, prijateljima ili poznanicima.

Prikaz 3. Dojam i ponovno korištenje online trgovine s AR-om

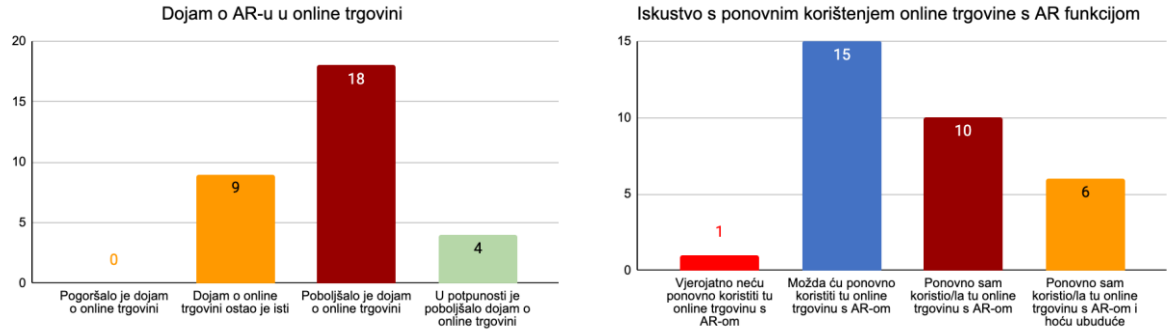

Izvor: Autorice

5.3. STAVOVI ISPITANIKA O PROŠIRENOJ STVARNOSTI

Na skup pitanja o razumijevanju proširene stvarnosti i njenoj primjeni u online trgovini ponovno su odgovarali svi ispitanici. Pitanjima su se željeli ispitati stavovi ispitanika o AR-u koji se nisu nužno temeljili na prethodnom iskustvu korištenja AR-a. Veći dio ispitanika smatra da im je lako razumjeti proširenu stvarnost i povezane tehnologije (35,6%), a s time se apsolutno slaže 22,2% ispitanika, no dobar dio ispitanika je neodlučan po pitanju te tvrdnje (34,1%).

U Tablici 2 prikazana su mišljenja i potencijalna ponašanja kupaca u online trgovini koja integrira AR funkciju za isprobavanje proizvoda. Može se uočiti da bi za većinu ispitanika proširena stvarnost olakšala odluku o odabiru i konačnoj kupnji proizvoda, naročito onog kojeg se bez AR-a ne bi usudili kupiti.

Tablica 2. Neka mišljenja ispitanika o AR-u prilikom online kupovine

	1 - uopće se ne slažem	2 - ne slažem se	3 - niti se ne slažem niti se slažem	4 - slažem se	5 - apsolutno se slažem
Ako bih prilikom online kupnje imao/la opciju korištenja AR-a i tako vidjeti i isprobati proizvode, smatram da bi mi to pomoglo u odabiru i kupnji.	1,5%	8,1%	18,5%	**41,5%**	**30,4%**
Ako bih prilikom online kupnje imao/la priliku isprobati **skuplji** proizvod kroz korištenje proširene stvarnosti, smatram da bi se tada prije odlučio/la za kupnju tog proizvoda.	0,7%	15,6%	**32,6%**	**31,9%**	19,3%
Ako bih prilikom online kupnje imao/la priliku isprobati **novi** proizvod uz korištenje AR-a, kojeg još nisam koristio/la zbog nesigurnosti u kvalitetu i funkcionalnosti, smatram da bi se tada prije odlučio/la za kupnju tog proizvoda.	1,5%	9,6%	**31,1%**	**40,0%**	17,8%
Ako bih bio/la zadovoljan/na aplikacijama koje omogućuju isprobavanje proizvoda ili usluga kroz AR, svakako bih to preporučio/la i svojoj obitelji/prijateljima i poznanicima.	0,7%	5,2%	19,3%	**43,7%**	**31,1%**

Izvor: Autorice (prema Karlica, 2023)

Unatoč vrlo pozitivnim mišljenjima, najveći dio ispitanika (44,4%) nije siguran bi li češće koristio online trgovinu s AR-om, u odnosu na fizičku prodavaonicu. Češće bi je koristilo 34,1% ispitanika, dok 21,5% ispitanika preferira fizičku trgovinu. Bez obzira na to, ispitanici smatraju da proširena stvarnost daje bolji uvid u asortiman proizvoda/usluga poduzeća – s time se slaže ili u potpunosti slaže 69,6% ispitanika. Ipak, dobar dio ispitanika (32,6%) smatra da AR nije prikladna za sve korisnike bez obzira na dob, a u to nije sigurno 39,3% ispitanika. Najveći dio ispitanika (34,8%) niti se slaže niti ne slaže s tvrdnjom da je AR prikladna za sve razine obrazovanja.

Bez obzira na to, velika većina ispitanika (75,6%) smatra da se poduzeće, koje koristi proširenu stvarnost za prikaz svojih proizvoda ili usluga, ističe se u odnosu na konkurenciju.

6. ZAKLJUČAK

Osnovna svrha proširene stvarnosti je korisniku omogućiti osjetilnu promjenu realnosti i pružiti dodatne informacije radi osobne ili poslovne potrebe. Ona miješa računalno generirane elemente s prikladnim elementima iz ljudske stvarnosti, omogućava interakciju korisnika s tim informacijama u stvarnom vremenu te u 3D prostorima stvara sklad između virtualnog i stvarnog. Svoju svrhu, osim u igrama, pronalazi u različitim sferama ljudskog života, a značajniji utjecaj među ostalim ostavila je u edukaciji i medicini te u posljednje vrijeme u marketingu i online trgovini.

U ovom radu predstavljeno je anketno istraživanje provedeno na prigodom uzorku ispitanika koji su podijelili svoja iskustva i mišljenja o proširenoj stvarnosti i online trgovini koja omogućuje isprobavanje proizvoda ili usluga kroz proširenu stvarnost. Na prvo istraživačko pitanje, o iskustvima hrvatskih potrošača u korištenju proširene stvarnosti prilikom online kupovine, možemo dati odgovor da su iskustva ispitanika vrlo pozitivna jer je za preko 70% ispitanika bilo jednostavno koristiti AR funkciju unutar online trgovine te su bili zadovoljni dodatnim informacijama o proizvodu koje su dobili kroz AR. Proširena stvarnost pomogla im je u odabiru i donošenju konačne odluke o kupovini, poboljšala je dojam o online trgovini i potakla ih da ponovno koriste istu online trgovinu.

Na drugo istraživačko pitanje o stavovima hrvatskih potrošača o primjeni proširene stvarnosti u online kupovini, velika većina smatra da bi im AR pomogla u odabiru proizvoda te olakšala odluku o kupovini novog ili skupljeg proizvoda. Proširena stvarnost doprinosi i poduzeću jer se kroz AR poduzeće ističe u odnosu na konkurenciju i pruža bolji uvid u asortiman proizvoda ili usluga. Osim ovih pozitivnih stavova, kod dijela ispitanika uočava se nesigurnost s novom tehnologijom jer dio ispitanika smatra da AR nije prikladna za sve dobi ili razine obrazovanja.

Iako se ovo istraživanje ne može generalizirati jer se temelji na prigodnom uzorku s najvećim brojem ispitanika iz Varaždinske županije i mlađe dobne skupine, rezultati istraživanja daju naslutiti da su se s proširenom stvarnošću dosad susretali najviše mlađi visokoobrazovani ispitanici. Dok je većina ispitanika čula za proširenu stvarnost, tek oko 40% dio ispitanika je nju i isprobao, najviše kroz filtere društvenih mreža ili videoigre. No, tek manji broj ispitanika (28,2%) koristio je proširenu stvarnost tijekom online kupovine. Stoga je mali uzorak od 31 ispitanika koji su isprobali AR u online trgovini dodatno ograničenje ovog istraživanja. Ipak, kroz istraživanje je utvrđen pozitivan odnos hrvatskih kupaca prema proširenoj stvarnosti. Možemo zaključiti da proširena stvarnost ima potencijala utjecati na donošenje poslovnih

odluka ili u privatnom životu za donošenje jednostavnih personaliziranih odluka, stoga se očekuje njena sve veća i raznolika primjena u svim sferama života.

REFERENCE

[1] *Augmented Reality for Travel and Tourism Industry | Zeal AR.* (2021). Preuzeto 30.08.2023. s https://zealar.com.au/augmented-reality-in-tourism-industry/

[2] BasuMallick, C. (2022). *Mixed Reality Definition, Working, and Applications.* Preuzeto 27.07.2023. s https://www.spiceworks.com/tech/innovation/articles/mixed-reality/

[3] Carmigniani, J., & Furth, B. (2011). Augmented Reality: An Overview. In F. Borko (Ed.), *Handbook of Augmented Reality.* Springer New York. https://doi.org/10.1007/978-1-4614-0064-6

[4] Chen, Y., Wang, Q., Chen, H., Song, X., Tang, H., & Tian, M. (2019). An overview of augmented reality technology. *Journal of Physics: Conference Series,* 1237(2), 022082., str. 1.-3. https://doi.org/10.1088/1742-6596/1237/2/022082

[5] Digital Promise (bez dat.). *Types of AR.* Preuzeto 27.07.2023. s https://digitalpromise.org/initiative/360-story-lab/360-production-guide/investigate/augmented-reality/getting-started-with-ar/types-of-ar/

[6] Dilmegani, C. (2023). *Augmented Reality (AR): What It is, How It Works, Types & Uses.* Preuzeto 30.07.2023. s https://research.aimultiple.com/augmented-reality/

[7] Episcopal School of Baton Rouge. (2021). *Episcopal Faculty/Staff Deploy Futuristic Tech to Engage Students.* Preuzeto 30.07.2023. s https://www.episcopalbr.org/knightly-news?id=151445/faculty-staff-deploy-futuristic-tech-to-engage-tomorrow-s-leaders

[8] Genetic Engineering and Biotechnology News. (2021). *Mission to Mars AR.* Preuzeto 26.08.2023. s https://www.genengnews.com/best-apps/mission-to-mars-ar/

[9] GeoSLAM (bez dat.) *What is SLAM?* Preuzeto 27.07.2023. s https://geoslam.com/what-is-slam/

[10] Karlica, A. (2023). *Primjena proširene stvarnosti u prodaji* (neobjavljeni diplomski rad). Varaždin: Sveučilište u Zagrebu, Fakultet organizacije i informatike.

[11] Khan, T. H. (2023). *Augmented Reality in Everyday Life: How AR is Transforming Industries.* Preuzeto 28.08.2023. s https://medium.com/@khanographyy/augmented-reality-in-everyday-life-how-ar-is-transforming-industries-1ed6d4ef280d

[12] Microsoft Dynamics 356 (2023). *What is Augmented Reality (AR) | Microsoft Dynamics 365.* Preuzeto 26.08.2023. s https://dynamics.microsoft.com/en-us/mixed-reality/guides/what-is-augmented-reality-ar/

[13] Nađ, K. (2021). *PROŠIRENA STVARNOST I VIRTUALIZACIJA KAO NADOPUNA SUVREMENIM MARKETINŠKIM AKTIVNOSTIMA : Diplomski rad* (Diplomski rad). Osijek: Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku. Preuzeto 30.8.2023. s https://urn.nsk.hr/urn:nbn:hr:145:574687

[14] Nextech (2022). *What Are the Different Types of Augmented Reality?* Preuzeto 28.08.2023. s https://www.nextechar.com/blog/what-are-the-different-types-of-augmented-reality

[15] Peel X (2023). *Peel X explain Augmented Reality apps*. Preuzeto 28.08.2023. s https://peelx.co.uk/peel-x-explain-augmented-reality-apps/#section15

[16] Sarvaiya, D. (2019). *Behind-the-Screen Technologies That Make Augmented Reality Work.* Preuzeto 30.08.2023. s https://learn.g2.com/augmented-reality-technologies

[17] Shaw, N., Eschenbrenner, B., & Baier, D. (2022). Online shopping continuance after COVID-19: A comparison of Canada, Germany and the United States. *Journal of*

Retailing and Consumer Services, 69(1), 103–100. https://doi.org/10.1016/j.jretconser.2022.103100

[18] Snapchat. (2021). T*he Next Inflection Point: More Than 100 Million Consumers Are Shopping with AR | Snapchat for Business.* Preuzeto 29.08.2023. s https://forbusiness.snapchat.com/blog/the-next-inflection-point-more-than-100-million-consumers-are-shopping-with-ar

[19] Solbiati, M., Passera, K. M., Rotilio, A., Oliva, F., Marre, I., Goldberg, S. N., … Solbiati, L. (2018). Augmented reality for interventional oncology: proof-of-concept study of a novel high-end guidance system platform. *European Radiology Experimental*, 2(1). https://doi.org/10.1186/s41747-018-0054-5

[20] Statista. (2023a). *AR Advertising - Worldwide | Statista Market Forecast*. Preuzeto 29.08.2023. s https://www.statista.com/outlook/amo/ar-vr/ar-advertising/worldwide

[21] Statista. (2023b). *AR & VR - Worldwide | Statista Market Forecast.* Preuzeto 29.08.2023. s https://www.statista.com/outlook/amo/ar-vr/worldwide

[22] Tacgin, Z. (2020). *Virtual and Augmented Reality: An Educational Handbook.* Cambridge Scholars Publishing

[23] Tan, Y.-C., Chandukala, S. R., & Reddy, S. K. (2021). Augmented Reality in Retail and Its Impact on Sales. *Journal of Marketing*, 86(1), str 48–66. https://doi.org/10.1177/0022242921995449

[24] Tremosa, L. (2023). *Beyond AR vs. VR: What is the Difference between AR vs. MR vs. VR vs. XR?* Preuzeto 29.08.2023. s https://www.interaction-design.org/literature/article/beyond-ar-vs-vr-what-is-the-difference-between-ar-vs-mr-vs-vr-vs-xr

[25] Webwise (bez dat.). *What is Pokemon Go? Explainer Guide.* Preuzeto 29.8.2023. s https://www.webwise.ie/parents/pokemon-go/

[26] Yoo, J. (2023). The effects of augmented reality on consumer responses in mobile shopping: The moderating role of task complexity. *Heliyon*, 9(3), e13775. https://doi.org/10.1016/j.heliyon.2023.e13775

Preliminary communication / Prethodno priopćenje

PRIMJENA LEAN MENADŽMENTA U POSLOVANJU: METODA SLUČAJA

BRUNO MATAUŠIĆ
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
bmatausic@student.foi.hr

MARINA KLAČMER ČALOPA
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
marina.klacmer@foi.hr

KAROLINA KOKOT
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
kkokot@foi.unizg.hr

SAŽETAK

Poduzeća u današnje vrijeme djeluju u uvjetima promjenjivosti, nesigurnosti, složenosti i dvosmislenosti. Kako bi odgovorila na navedene uvjete, poduzeća se usmjeravaju na kontinuirana poboljšanja svih aspekata poslovanja, a upravo primjena lean odnosno vitke metodologije omogućuje ostvarivanje konkurentske prednosti putem kontinuiranog poboljšanja. Cilj rada je identificiranje temeljnih problema i prilika prilikom provođenja lean menadžmenta u poduzeću, te identificiranje prednosti uvođenja navedene metodologije kroz utjecaj na performanse kao i trendova u području lean metodologije. Pregled literature analiziran je putem bibliometrijske analize pojmova povezanih s lean menadžmentom, primjenom analize ključnih riječi, dok se empirijski dio rada temelji na kvalitativnom istraživanju, metodi slučaja. Metoda studija slučaja provedena je putem intervju-a menadžera u poduzeću koji primjenjuje lean metodologiju u poslovanju. Nakon provedbe bibiliometrijske analize i studije slučaja uspoređeni su dobiveni rezultati u cilju definiranja odgovora na istraživačka pitanja. Rezultati analize potvrdili su teorijske pretpostavke kao i dosadašnje rezultate empirijskih studija.

KLJUČNE RIJEČI: lean metodologija, lean menadžment, performanse, bibliometrijska analiza, studija slučaja

LEAN MANAGEMENT IMPLEMENTATION: CASE STUDY

ABSTRACT

Companies operate in conditions characterized by variability, uncertainty, complexity and ambiguity. How to respond to this condition, companies are focused on continuous improvements of all business aspects, and lean methodology allows them to reach competitave advantages through continuous improvement. The paper aims to identify problems and possibilities in lean methodologyimplementation and identify advantages of lean implementation by positive impact on performance and recognition of trends in this field. The literature review was done by bibliometrics analysis and co-word analysis; the empirical part is qualitative research, a case study. An interview as the case study with managers in the company that implement lean methodology. Bibliometric analysis and case study results were compared to define responses to research questions. Analysis results confirmed the theoretical assumptions and present research results.

KEYWORDS: lean methodology, lean management, performance, bibliometric analysis, case study

1. UVOD

Uvjete unutar kojih suvremena poduzeća djeluju karakterizira visoka razina neizvjesnosti, intenzivne promjene te visoka očekivanja klijenata. U cilju prilagodbe poduzeća na uvjete kao i na sveprisutne promjene u potražnji, poduzeća moraju biti u mogućnosti promijeniti dosadašnji strateški pristup u poslovanju s ciljem stvaranja konkurentske prednosti i vrhunskih performansi. Nadalje, kontinuirane promjene na tržištu zahtijevaju od poduzeća fleksibilnost koja omogućava brzu reakciju bez generiranja dodatnih troškova za poduzeće [Klačmer Čalopa i sur., 2022]. Implementacija *lean* ili tzv. vitke metodologije u svakodnevno poslovanje omogućuje poduzećima kontinuirano poboljšanje svih aspekata poslovanja što dovodi do poboljšanja performansi poduzeća, a posljedično do ostvarivanja konkurentskih prednosti.

Poslovna praksa koja uključuje *lean* pristup potječe iz 20. stoljeća te poduzeća koja se smatraju „*lean organizacijama*“ nastoje funkcionirati na način da održavaju razinu i performanse odvijanja trenutnih procesa uz istovremeno unaprjeđenje tih procesa. Temeljni cilj *lean* menadžmenta te vezanih tehnika i metoda je eliminacija aktivnosti koje ne dodaju nikakvu vrijednost promatrajući iz perspektive klijenta, odnosno smanjenje stvaranja otpada u svim oblicima kao procesa, inventara ili škarta. Lean filozofija, koja izvorno dolazi iz Toyotinog proizvodnog sustava, predstavlja inicijativu koju veliki broj poduzeća pokušava implementirati u cilju pojednostavljenja proizvodnih procesa i optimizacije resursa [Womack i sur., 1991; Schonbergerm, 2007 prema Karim i Arif-Uz-Zaman, 2013]. Lean proizvodnja je tijekom godina evoluirala u filozofiju menadžmenta s naglaskom na povećanju vrijednosti za kupca i uklanjaju aktivnosti koje nemaju navedenu vrijednost [Hegedić, Gudlin i Štefanić, 2018].

Lean menadžment je poslovni model koji isporučuje superiorne performanse za klijente, zaposlene, dioničare i društvo u cjelini [Bhasin, 2012]. Charon i sur. [2014] definiraju lean menadžment kao „*Sistematičan i vrlo fokusiran pristup kod vođenja učenja zaposlenika, edukacije i prakticiranje lean principa i filozofija kroz čitavo poduzeće*.“ Womack i Jones [1997] definiraju pet vrijednosti koje se vežu uz lean filozofiju: vrijednost, bilježenje protoka

vrijednosti, stvaranje kontinuiranog toka, definiranje sustava „povlačenja“ te stalno poboljšanje. Nadalje, karakteristike lean metodologije [Pettersen, 2009 prema Anđelković, Radosavljević i Stošić] jesu: *just in time* praksa, smanjenje sirovina, upravljanje ljudskim potencijalima, poboljšanje strategija, kontrola škarta, upravljanje lancima nabave, standardizacija, znanstveni pristup upravljanju i tehnike. Lean filozofija i alati pospješuju kontinuirana poboljšanja u širokom rasponu industrijskih aktivnosti obuhvaćajući područja kao što je održavanje, kvaliteta, logistika i planiranje [Pombal i sur., 2019]. Lean metodologija obuhvaća veliki broj alata, a u svojem radu Singh i Kumar [2019] istaknuli su neke od najzastupljenijih - vizualizacija radnih mjesta, kontinuirana poboljšanja, mapa toka vrijednosti i BIM (engl. *Building Information Modeling*). Poppendieck [2002] ističe kako su principi razvoja leana sljedeći: dodavanje isključivo vrijednosti i eliminacija otpada, usredotočenost na ljude koji stvaraju vrijednost, brzi protok na temelju potražnje (*pull* sistem) i optimizacija cijele organizacije.

Kada se lean metodologija primijeni na odgovarajući način doprinosi konkurentnosti poduzeća poboljšavajući sveukupne performanse, iako je implementacija zahtjevan i dugotrajan proces [Bhasin, 2012]. Iz navedenog razloga, postoji interes akademske zajednice za analiziranjem procesa implementacije lean pristupa u poduzeća i rezultatima utjecaja istog na performanse poduzeća. Jasti i Kodali [2015] u svom pregledu literature identificirali su povećanje empirijskih radova što ukazuje na rastući interes za navedenim područjem u znanstvenoj zajednici do 2011. godine te se provela bibliometrijska analiza kako bi se utvrdila situacija znanstvene produkcije zadnjeg desetljeća.

Cilj rada je identificirati dosadašnja znanstvena dostignuća u području lean menadžmenta i povezati s poslovnim slučajem. Kako bi se identificirali današnji trendovi u znanstvenim radovima, ali i poslovnoj praksi, primjenom kombinacije metoda bibliometrijske analize i metode slučaja definirana su sljedeća istraživačka pitanja:

- *Kakva je znanstvena produktivnost i zastupljenost zemalja u znanstvenom području?*
- *Koji ključni pojmovi su najzastupljeniji u području lean menadžmenta?*
- *Kakvi su trendovi u području lean menadžmenta i preporuke za buduća istraživanja?*
- *Kakva je povezanost znanstvene literature i prakse?*
- *Koje su ključne prednosti i nedostaci uvođenja lean metodologije u poslovanje?*

2. BIBLIOMETRIJSKA ANALIZA

2.1. METODOLOGIJA

Platforma Web of Science (*WOS*) s bazom koja sadržava više od 13.000 časopisa [Mongeon, Paul-Hus, 2016] predstavlja odgovarajući izbor za provedbu bibliometrijske analize [Fang i sur. 2018 prema Zhang, Quoquab i Mohammad]. Sukladno tome, za predmetnu analizu odabrana je WOS platforma. Bibliometrijska analiza prikladan je način za bolje razumijevanje postojećeg stanja u definiranom znanstvenom području kao i identificiranje preporuka za buduća istraživanja [Zhang, Quoquab i Mohammad, 2023]. Kao jedan od oblika bibliometrijske analize, analiza ključnih riječi (eng. *co-word analysis*), omogućava identificiranje najistaknutijih aspekata unutar određenog znanstvenog područja. Analiza ključnih riječi provedena je na način da su analizirani svi sažeci radova obuhvaćeni analizom, a način definiranja baze radova opisan je u Tablici 1. Cilj analize ključnih riječi je identificirati pojmove koji se najčešće javljaju u sažecima radova koji su predmet bibliometrijske analize kako bi se

mogli donijeti zaključci o tome koji su najzastupljeniji pojmovi u analiziranom području. Dobiveni rezultati grafički će se prikazati korištenjem softwarea *VOSviewer* i *Biblioshiny*.

Autori su podatke za bibliometrijsku analizu prikupili 12. srpnja 2023. godine, obuhvativši cijeli vremenski horizont objavljenih članaka na navedenoj platformi. Prema podacima platforme WOS, prvi članak na temu lean metodologije objavljen je 1996. godine. Detaljan proces prikupljanja baze za bibliometrijsku analizu s kriterijima prikazan je u Tablici 1. Na platformi WOS upisan je pojam „lean methodology", a u bazu su uključeni članci u kategorijama „*management and business*" te *Social Sciences Citation Index*. Na temelju definiranih kriterija, baza radova za analizu obuhvatila je ukupno 799 radova.

Tablica 1. Detalji pretraživanja platforme WOS

Kriteriji	**Opis**
Platforma	Web of Science
Period	Nije definiran
Pojmovi za pretraživanje	Lean metodologija (eng. *Lean methodology*)
Kriteriji za uključivanje članaka	Članci Kategorija: *management and business* *Social Sciences Citation Index*
Ukupno članaka uključenih u analizu	799

(Izvor: izrada autora)

2.2. REZULTATI BIBLIOMETRIJSKE ANALIZE

Kao što je prethodno spomenuto, najstariji članak obuhvaćen bibliometrijskom analizom, u području lean metodologije datira iz 1996. godine. Detaljna analiza znanstvene produktivnosti kroz navedeni period od 28 godina, ukazuju na znatno povećanje znanstvene produktivnost u zadnjem desetljeću. Prvo povećanje identificirano je u 2014. godini, dok je u 2020. identificiran najznačajniji porast. Porast u 2020. godini može se povezati s pojavom COVID-19 pandemije, u kojoj su poduzeća bila usmjerena na smanjenje troškova i povećanje produktivnosti, a lean metodologija može biti jedan od strateških pristupa poduzeća za ostvarivanje navedenog cilja. Pandemija je rezultirala povećanjem razine volatilnosti okruženja što menadžere u organizacijama navodi da provode promjene, a organizacije u različitim područjima usmjerile su se na lean metodologiju kao jedan od dokazanih pristupa za pomoć u poboljšanju performansi [mckinsey.com, 2020]. Znanstvena produktivnost u području lean metodologije za analiziranu platformu prikazana je Slikom 1.

Slika 1. Znanstvena produktivnost u području lean metodologije po godinama

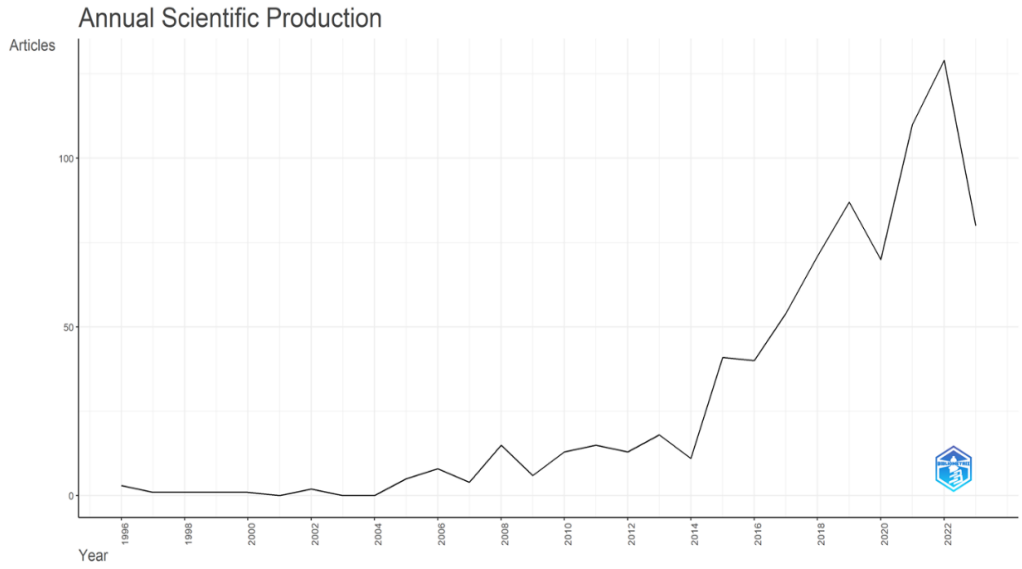

(Izrada autora: software Biblioshiny)

Tablica 2 prikazuje znanstvenu produktivnost autora po zemljama, a analizom baze radova utvrđeno je kako je najmanje 67 zemalja objavilo barem jedan članak koji obuhvaća pojam lean metodologija, što znači kako barem jedan autor dolazi iz neke od zemalja. Vidljivo je kako u objavama visoku poziciju ima Ujedinjeno Kraljevstvo s 239 članka, sljedeća je Indija s 194 te Sjedinjene Američke Države s 191 objavom. Rezultati su u skladu s bibliometrijskom analizom autora Singh i Kumar [2019] koji su također identificirali nerazmjer između zemalja. Važno je spomenuti kako navedena analiza obuhvaća suautorstvo, što znači da nije uvjet da svi autori budu iz navedene zemlje, već su uključene internacionalne mreže za suradnju. Zanimljivo je kako u navedenoj bazi, uz zadane kriterije, samo je jedan članak autora iz Hrvatske. Navedena tablica izrađena je putem programa *Biblioshiny*.

Tablica 2. Popis zemalja i broj članaka

Zemlja	**Broj**
UK	239
INDIA	194
USA	191
BRAZIL	126
CHINA	93
ITALY	89
AUSTRALIA	72
SPAIN	65
SWEDEN	43
NETHERLANDS	42
NORWAY	40
MALAYSIA	37
IRELAND	35
CANADA	32
NEW ZEALAND	30
PORTUGAL	30

TURKEY	30
DENMARK	23
GERMANY	20
MEXICO	18
FRANCE	17
MOROCCO	17
PAKISTAN	16
INDONESIA	15
IRAN	15
JORDAN	15
CHILE	14
SAUDI ARABIA	14
SWITZERLAND	14
SOUTH KOREA	11
BANGLADESH	10
FINLAND	10
HUNGARY	10

BELGIUM	9
EGYPT	9
GREECE	9
SRI LANKA	9
ARGENTINA	8
POLAND	8
SOUTH AFRICA	8
GHANA	7
THAILAND	7
URUGUAY	6
VIETNAM	6
ISRAEL	5
JAPAN	5
LITHUANIA	5
NIGERIA	5
AUSTRIA	4
ROMANIA	4

CZECH REPUBLIC	3
LEBANON	3
NAMIBIA	3
QATAR	3
SINGAPORE	3
COLOMBIA	2

ECUADOR	2
ESTONIA	2
KUWAIT	2
LATVIA	2
BULGARIA	1
CROATIA	1

HONDURAS	1
KAZAKHSTAN	1
NORTH MACEDONIA	1
RUSSIA	1
ZIMBABWE	1

(Izvor: Izrada autora prema podacima Biblioshiny)

Analiza ključnih riječi (Slika 2) odrađena je u *VOSviewer* softwareu, a ukazala je na najvažnije pojmove na području lean metodologije: Performanse (248), implementacija (229), menadžment (193) i utjecaj (154). Navedeni pojmovi istaknuti su prema interesu znanstvene zajednice za područja poput performanse poduzeća (financijske i nefinancijske), važnost menadžmenta za proces implementacije navedene metodologije, kao i proces implementacije u cilju identificiranja razloga zašto su neke organizacije uspješnije u odnosu na druge.

Slika 2. Rezultati analize ključnih riječi

(Izvor: izrada autora pomoću Biblioshiny)

Slikom 3 prikazani su trendovi tema u području lean metodologije po godinama. Može se identificirati kako su 2019. godine u znanstvenoj literaturi prevladavali aspekti performanse i utjecaj, dok 2020. godine fokus se usmjerio na implementaciju i menadžment. U posljednjih nekoliko godina fokus u području lean metodologije usmjerava se na prilike i održivost te se navedeno područje prema učestalosti pojave može definirati kao potencijal za buduća istraživanja jer je vidljivo kako navedena područja nisu značajno zastupljena u analiziranim člancima. Prilikom interpretacije navedenih rezultata bibliometrijske analize potrebno je istaknuti činjenicu kako se odnose isključivo na analiziranu bazu koja je preuzeta na platformi WOS, uz definirane kriterije što se ujedno smatra i jednim od najvećih ograničenja rada.

Slika 3. Trendovi tema u području lean metodologije

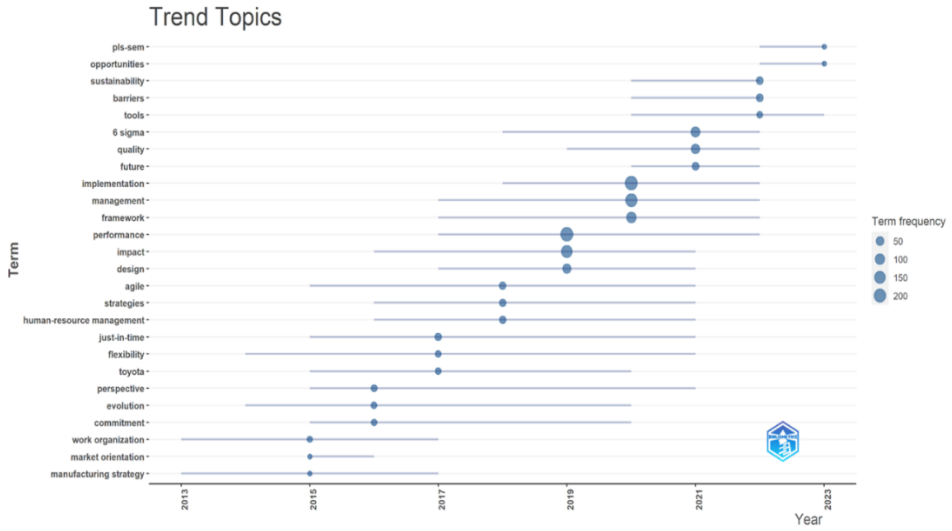

(Izvor: izrada autora u softwareu Biblioshiny)

3. METODA SLUČAJA

U okviru metode slučaja proveden je intervju s dvoje zaposlenika na pozicijama senior inženjer i voditelj klijenata (engl. *Senior tech engineer i Account manager*] u komunikacijskoj digitalnoj agenciji. Cilj provedbe intervjua bio je prikupiti informacije o iskustvu s lean metodologijom unutar poduzeća, o primjeni pojedinih alata, razmišljanju vezanom uz uklanjanje otpada i ostale elemente lean metodologije. Kod implementacije lean metodologije često je riječ o nesistematičnom pristupu, iako znatan broj poduzeća primjenjuje neke od lean principa [Klačmer Čalopa, Kokot i Đunđek Kokotec, 2022] i upravo provedba intervjua omogućava dublju sliku poslovanja i analiziranja primjene lean metodologije.

Prije svega, potvrđena je teorijska pretpostavka kako su poduzeća sve više usmjerena na potrebe klijenata, što ukazuje sljedeća tvrdnja „*Istaknula bih da je još važnije razumjeti klijenta i pokušati sam shvatiti što bi potencijalno mogao biti problem ili što bi trebalo biti potrebno za rješavanje određene situacije*.“ U početnoj fazi intervjua jasno je istaknuta potreba poduzeća za personaliziranijem usluga koje poduzeće pruža na tržištu.

Tijekom intervjua istaknuto je kako se većina njihovih usluga pruža prema *pull sistemu*, odnosno „M*ožemo imati odličnu ideju, ali ona mora biti vezana uz činjenicu da postoji problem bilo kod kupaca našeg klijenta, odnosno njegovih potrošača bilo kod samog klijenta*“ (iz intervjua). Navedeno ukazuje kako poduzeće svoje usluge nudi isključivo na potrebama potražnje, čime se smanjuju usluge koje nisu tražene na tržištu.

Iako poduzeće nudi usluge koje su personalizirane, određeni procesi su standardizirani na razini klijenata, kao i faze svake pojedine usluge „*Proces je standardiziran od prikupljanja zahtjeva od klijenta, razvoja plana strategije i taktika do produkcije i dostave. Proizvodi, odnosno usluge koje nudimo i radimo za klijenta standardizirane su u okviru svakog odjela i same struke*“ (iz intervjua).

Vezano uz otpad istaknuto je kako sugovornici smatraju kako je otpad „*Gubitak vremena bilo kakve vrste. Ali i korekcija zahtijevana od strane klijenta, pogotovo puno korekcija. Znači da*

nešto bilo nejasno u samom procesu.“ Vidljivo je kako imaju identificirane otpade u poslovanju i kako pokušavaju smanjiti njihovu količinu. Ono što je istaknuto tijekom intervjua su aplikacije koje se koriste u internim procesima i poslovanju poduzeća, a dovode do smanjenja otpada u obliku gubitka vremena. Navedeno ukazuje na potencijal digitalnih tehnologija i digitalne transformacije poslovanja kao jednu od mogućnosti smanjenja otpada svih vrsta poput softwarea za potrošnju sati, raspodjelu zadataka, financije i slično.

Ono što je istaknuto je i kontinuirano poboljšanje svih procesa kao dugoročna investicija, odnosno „*Isplativo je, ali dugoročno. Nije kratkoročno. Mi i dalje prodajemo usluge i gledamo svoju profitabilnost utrošenog u odnosu na prodano*“ (iz intervjua). Iako je nesporno kako su kontinuirana poboljšanja svakodnevica uspješnih poduzeća „*mislim da nijedno uspješno poduzeće neće funkcionirat ako se s vremenom ne nadograđuje i poboljšava svoje procese*“ (iz intervjua).

4. RASPRAVA

Rezultati bibliometrijske analize u području lean menadžmenta ukazuju na povećanje znanstvene produktivnosti, posebno zadnjih nekoliko godina, iako je interes znanstvene zajednice već početkom 2000-tih rastao [Jasti i Kodali, 2015]. Navedeno ukazuje kako područje još uvijek ima praznina u znanstvenim rezultatima, ali i na činjenicu kako je lean metodologija jedan od strateških pristupa poduzeća, posebno zastupljena u suvremenim uvjetima poslovanja. Bibliometrijska analiza identificirala je geografsku prazninu. Zemlje koje su najzastupljenije u znanstvenim radovima su Ujedinjeno Kraljevstvo, Indija, Sjedinjene Američke Države, dok se Hrvatska nalazi na samom začelju zastupljenosti zajedno s velikim brojem zemalja koji imaju manje od 5 članaka. Navedeno otvara brojne mogućnosti znanstvenicima u području lean metodologije. Analiza ključnih riječi identificirala je kako su najzastupljeniji pojmovi u promatranom području performanse, implementacija, menadžment i utjecaj, dok se kao pojmovi u novije vrijeme ističu prilike, održivost i prepreke, što predstavlja smjer i preporuke za buduća istraživanja.

Metoda slučaja istaknula je kako se u analiziranom poduzeću mogu prepoznati alati i lean principi koji se primjenjuju. Prije svega, fokus na smanjenju otpada svih vrsta, ali i kontinuirana poboljšanja. Istaknuto je kako je navedeno osnova uspješnog poslovanja u današnjim uvjetima. Rezultati metode slučaja ukazali su i na potencijal digitalne transformacije poduzeća u uvođenju lean metodologije. Metoda slučaja ukazala je prilike koje lean metodologija uz principe i alate nudi poduzećima, ali i izazov u pogledu dugoročnosti investicije, što je istaknuo Bhasin [2012]. Identificirana je povezanost znanstvene literature i prakse, odnosno lean principi identificirani bibliometrijskom analizom autora Poppendieck [2002] primjenjivani su u analiziranom poduzeću (brzi protok na temelju potražnje, eliminacija otpada) kao i lean alati poput kontinuiranog poboljšanja [Singh i Kumar, 2019]. Nadalje, metoda slučaja ukazuje kako je osnovna prednost lean metodologije održavanje konkurentske prednosti i kontinuirano poboljšanje bez kojeg nema uspješnosti poslovanja, dok su nedostaci dugoročna isplativost investicije i financijski i vremenski zahtjevan proces implementacije. Svakako, potencijal digitalne tehnologije i procesa digitalne transformacije s aspekta lean metodologije predstavlja nedovoljno zastupljeno područje i svakako preporuku za buduća istraživanja.

Rad ima i prepoznata ograničenja. Korištenje samo jedne baze znanstvenih radova, dovodi do isključenja znanstvenih radova u ostalim bazama i prilikom interpretacije rezultata bibliometrijske analize nužno je istaknuti navedeno. Nadalje, provedba metode slučaja na

isključivo jednom poduzeću može rezultirati smanjenom objektivnošću dobivenih informacija i nemogućnošću usporedbe rezultata s ostalim poduzećima. Iako metoda slučaja pruža informacije o temi, preporuka je za buduća istraživanja metodom slučaja obuhvatiti veći broj poduzeća.

REFERENCE

[1] Anđelković, A.; Radosavljević, M.; Stošić, D. (2016). Effects of Lean Tools in Achieving Lean Warehousing. *Economic Themes, Sciendo*. 54(4), str. 517-534, 2008.

[2] Bhasin, S. (2012). Performance of Lean in large organisations. *Journal of Manufacturing Systems*, 31(3), str. 349–357. doi:10.1016/j.jmsy.2012.04.002.

[3] Charon, R. i suradnici (2014). *The Lean Management Systems Handbook*, CRC Press.

[4] Hegedić, M.; Gudlin, M.; Štefanić, N. (2018). Relationship between lean and green management in Croatian manufacturing companies. *Interdisciplinary Description of Complex Systems*, INDECS, 16(1), str. 21-39.

[5] Jasti, N.V.K.; Kodali, R. (2015). Lean Production: Literature Review and Trends. *International Journal of Production Research*, 53, str. 867-885.

[6] Karim, A.; Arif-Uz-Zaman, K. (2013). A methodology for effective implementation of lean strategies and its performance evaluation in manufacturing organizations, *Business Process Management Journal*, 19 (1), str. 169-196.

[7] Klačmer Čalopa, M.; Kokot, K.; Đunđek Kokotec, I. (2020). Level of Knowledge and Implementation of Lean Methodology in Small and Medium-sized Croatian Companies. *TEM Journal*, 9 (2020) str. 276-285

[8] Raedemaecker, S.; Handscomb, C.; Jautelat, S.; Rodriguez, M.; Wienke, L. (2020). McKinsey & Company, https://www.mckinsey.com/capabilities/operations/our-insights/lean-management-or-agile-the-right-answer-may-be-both, preuzeto: [27.8.2023.]

[9] Mongeon, P.; Paul-Hus, A. (2016). The journal coverage of Web of science and Scopus: A comparative analysis. *Scientometrics*, 106(1), str. 213–228.

[10] Poppendieck, M. (2002). Principles of Lean Thinking. https://nzbef.org.nz/wp-content/uploads/2019/05/Paper-Principles-of-Lean-Thinking.pdf, preuzeto [30.8.2023.]

[11] Singh, S.; Kumar, K. (2020). Review of literature of lean construction and lean tools using systematic literature review technique (2008–2018), *Ain Shams Engineering Journal*. 11(2), str. 465-471.

[12] Pombal, T. i suradnici (2019). Implementation of Lean Methodologies in the Management of Consumable Materials in the Maintenance Workshops of an Industrial Company. *Procedia Manufacturing* 38 (2019), str. 975–982.

[13] Womack, J. P.; Jones, D. T. (1997). Leanthinking—banish waste and create wealth in yourcorporation. *Journal of the Operational ResearchSociety*, 48(11), str.1148-1148

[14] Zhang, J.; Quoquab, F.; Mohammad, J. (2023). Plastic and sustainability: a bibliometric analysis using VOSviewer and CiteSpace. *Arab Gulf Journal of Scientific Research*.

Preliminary communication / Prethodno priopćenje

THE EFFECT OF HOTEL ROOM ATTRIBUTES ON HOTEL ROOM PRICES IN SPLIT: A HEDONIC APPROACH

MIHOVIL KOLOVRAT
mihovil.kolovrat@gmail.com

SLAĐANA PAVLINOVIĆ MRŠIĆ[1]
Sveučilište u Splitu
Ekonomski fakultet
Cvite Fiskovića 5, 21 000 Split, Hrvatska
spavlino@efst.hr

ABSTRACT

Hedonic pricing is a well-established and widely used method for estimation of effects of product attributes on a product price. The method is very often applied in a housing sector in order to understand a price formation. However, it is less often applied in a tourism sector to estimate attributes which affect the price of tourist accommodation.

This research improves understanding of a hotel room price formation in city Split and it complements to the existing literature on hedonic pricing in the tourism sector. Starting from the existing literature, it offers a final log-linear regression model with attributes of hotel rooms which are statistically significantly related to the prices. In line with the existing literature, it is found that guest reviews and number of stars are significant attributes. Unlike the majority of the existing literature, location factions are insignificant, while novel variable is rope and slippers which presence turn to affect room price significantly, as well as room surface.

The existing research is limited to one city and only on a high-season period. Thus, the model could be further tested for a larger spatial area, as well as for off-season period. Furthermore, more advanced econometric techniques may be considered for the future. Findings of this research can inform tourism manager in development of hotel pricing strategies.

KEYWORDS: *room rates; hotels; hedonic price; Split*

1. INTRODUCTION

The effect of hotel room attributes on hotel room prices is examined in this paper. Already, Castro and Ferreira (2015) stated that various attributes determine hotel room prices while Soler et al (2019) applied hedonic price model to measure the effect of various attributes on hotel prices. Previously, Zhang et al (2011) as well applied the same method do determine hotel room prices. Hedonic pricing was firstly introduced by Rosen (1974) who suggested that the goods are valued depending on their attributes or characteristics. Also, this paper adds as well the

[1] The author for the correspondence.

guest quantitative reviews of the hotel services which are available on the websites such as TripAdvisor.com or Booking.com.

2. DETERMINANTS OF PRICE FORMATION IN HOTEL INDUSTRY

Pricing tools represent only a part of revenue management tools used by hotels to maximize their yields (Ivanon and Zhechev, 2012). Information about importance of different accommodation for the final hotel room rate supports decision-makers in this process. Hotel revenue management literature involves consideration of pricing, demand modelling and forecasting, business analysis, inventory and price optimization, as well as other aspect which could affect business revenues (Binesh et al, 2016; Sanchez-Lozano, 2021). One of the approaches is to analyse certain good as a bundle of characteristics (attributes) which are offered at a total price. In fact, demand for hotel accommodation is modeled by applying various dependent variables such as average room rate, number of stars, guest reviews, cleanliness, comfort, value for money and location (Cezar and Ogut, 2016 in Binesh et al 2016:547).

Rosen (1974 in Sanchez-Lozano et al, 2021) suggests that implicit prices of those product features might be estimated by applying regression analysis. Hedonic analysis is usually applied to market prices which are defined by both, demand-side and supply-side forces. In order to study customer willingness to pay, different authors use supply-side explanatory variables to analyse their effects on hotel room prices. However, Masiero et al (2015:118) suggest that hedonic modelling which is very often used to study relationship between hotel room attributes and hotel room rates "may not reflect guests' genuine perceived value of hotel attributes" and instead apply discrete choice modeling design to study those relationships. The authors find that a harbor view instead of a city view strongly affects the willingness to pay for the room. Other attributes which strongly affect price are access to hotel club, and free beer and wine in the mini bar. Stated preference method was applied by Nelson et al (2021) as well to investigated the factor affecting willingness to pay for a local green hotel certification in a context of a small-island tourist destination by contingent valuation method. The authors find that guests staying in hotels with category are the most willing to pay a green price premium.

On the other hand, Sanchez-Lozano et al (2021) also apply hedonic price model and regression analysis to determine implicit prices, that is, to study the effect of attributes on a bundle price of a product package. They apply panel data analysis with random effects and find strong positive statistical significance of hotel-based and offer-based variables. More precisely, relevant for our setting, online rating, central location, tangible attributes, meal plan and hotel category were found to increase hotel room price. It is worth to note that instead of testing availability of parking, fitness room, swimming pole or spa separately, variable "tangible attributes" is created which counts a number of such attributes available in a hotel.

Sanchez-Lozano et al (2021) study three categories of supply-side variables: contextual variables (booking horizon, occupancy rates, day of the week, season, international and national holidays and trade fairs), hotel-based variables (number of rooms, brand affiliation, location, tangible attributes, star rating, and online rating), and offer-based variables (cancellation policies, type of room, meal plan, number of guests, and minimum length of stay).

Sanchez-Perez et al (2019) collect data on hotel prices and room attributes in several countries and apart from OLS analysis, apply quantile regression analysis since non-normality and heteroscedasticity was detected in data, together with a long-tail and asymmetric distributions. The analysis showed that slope coefficients and their significance differ across quantiles. The

authors find expected positive effects of category (number of stars), eWOM, and negative effect of average distance from the other hotels. Although Sanchez-Perez et al (2019) interpret the last as an indicators of a business concentration, it rather might reflect the hotel location in terms of vicinity to tourist attractions.

Chica-Olmo et al (2020) develops a spatial hedonic model for tourist accommodation since observed spatial variations in prices might be correlated due to spatial contagion in hosts price decision-making. They find that prices of tourist apartments in Malaga are spatially correlated, and thus estimate SAR and SEM models. The authors use two variables related to guest reviews: host rate with the maximum value if the guests are "totally" satisfied, and variable number of reviews. The authors find statistically significant negative correlation with accommodation prices which is justified by the fact that guests who pay less expensive apartments are less demanding and thus more satisfied with the accommodation, and by the findings in literature that cheaper apartments tend to have higher number of reviews.

Kim et al (2020) also studies spatial variability in hotel room rates and find that hotel class, service quality and distance from airport and highway have positive effects on hotel room price, while distance from tourist attractions has a negative effect.

On the other hand, Cai et al (2019) in a similar research but with a log-linear OLS model find that host rating has a slight positive effect on price of accommodation. In line with other research, authors find that a distance from tourist attractions negatively affects accommodation price. The debate on the role of host rating is further extended by Agušaj et al (2017:196) who explored a set of hotels in Dubrovnik-Neretva county (Croatia) and examined how number of hotel stars, guest reviews, and room pricing power are mutually related. The authors find a statistically significant difference in pricing for hotels with higher and lower online rating in case of four and give star hotels while the relationship was the opposite in the case of three star hotels (Agušaj et al, 2017:198). Furthermore, they find that star rating positively affected hotel pricing.

3. HEDONIC PRICING MODELS

Hedonic price function was usually applied to estimate asset or real state value (Tietenberg and Lewis, 2015). For example, it is expected that real estates in polluted area are less valued than those in clean areas since they are less attractive for living. Champ et al (2013) defines hedonic price function as follows:

$P = \alpha_0 + \sum_{i=1}^{h} \beta_i H_i + \sum_{j=1}^{n} \beta_j N_j + \sum_{k=1}^{L} \beta_k L_k + \varepsilon$	(1)

P – real estate price; H – structural attributes of the real estate (number of rooms or surface); N – attributes of neighborhood or surrounding (average income; quality of air); L – location attributes (vicinity of the city center). Linear, exponential or logarithmic regression models are usually applied.

Kunovac et al (2008) applied hedonic price model to estimate real estate price index in Croatia while spatial elasticity of flat prices was estimated by Boras and Tica (2013).

Andersson (2013) suggests that there are three groups of variables in hedonic price model applied in tourist accommodation sectors: room variables (various room content); hotel variables (for example, restaurant) and quality variables (guest reviews; number of stars or hotel chain membership).

Espinet et al (2003) applied hedonic approach to study attributes of holiday hotels in Spain. Statistically significant attributes were: four stars, hotel size, distance from the beach and availability of parking. Similar research was conducted by Chen and Rothschild (2010) for Taipei, Fleischer (2012) for Mediterranean coast and Andersson (2013) for Stockholm. Negative relationship between vicinity to the city center and prices, as well as a significant effect of conference centers, Internet connection and room size was found by Chen and Rothschild (2010). On the other hand, Andersson (2013) finds that vicinity to the city center increases the price of rooms, ceteris paribus. Fleischer (2012) finds that price of rooms with see view is 10% higher of those without a view. Finally, Masiero et al (2021 in Binesh et al 2016:547) find that "all business travelers were willing to pay more for a "room with a view"".

Chen and Rothschild (2010) concluded that location, LED television and availability of conference rooms are statistically significant attributes. Two empirical models were estimated, weekends, and working days. Availability of Internet and gym is significant only on weekends, while room size is significant only for model with working days. Only one night in double room was analyzed in order to standardize the analysis. The same approach was applied in this paper.

Zhang et al (2011) used data collection from TripAdvisor analyzed samples of three hotel categories. The results indicate that attribute significance varies across the categories. The guests in the luxury hotels value room cleanness, quality of service and location.

Finally, Pavlinović Mršić and Radman (2017) tested the relationship between the distance from the Diocletian Palace and the hotel room prices in Split. While the distance from the Diocletian Palace was not a statistically significant variable, the average review rating and availability of breakfast significantly affected price. Also, Mandić and Jurun (2018) investigated price determinants of small and family hotels and find that location is not statistically significant variable, while Mandić and Petrić (2020) find that proximity to national parks positively affects prices of hotel services.

This paper contributes by additional application of hedonic price model in tourism sector and by deepening the existing knowledge about importance of the hotel room attributes.

4. EMPIRICAL MODEL

In line with the reviewed literature the aim of this research is to examine the effect of hotel room attributes on their prices in Split by applying hedonic price function. Multiple log-linear regression model was estimated with hotel room as depended, and with 18 independed variables selected based on the literature review: stars, guest review, room surface, distance from the sea, distance from the city, sea view, city view, yard/garden view, breakfast, tub, minibar, private parking, robe and slippers, swimming pool, fitness, spa/wellness, room service, and kids friendly.

Stepwise method was applied to reduce the model, and only variables with statistical significance 5% or lower were selected in the final regression model.

Figure 1. Hotel room attributes on Booking.com

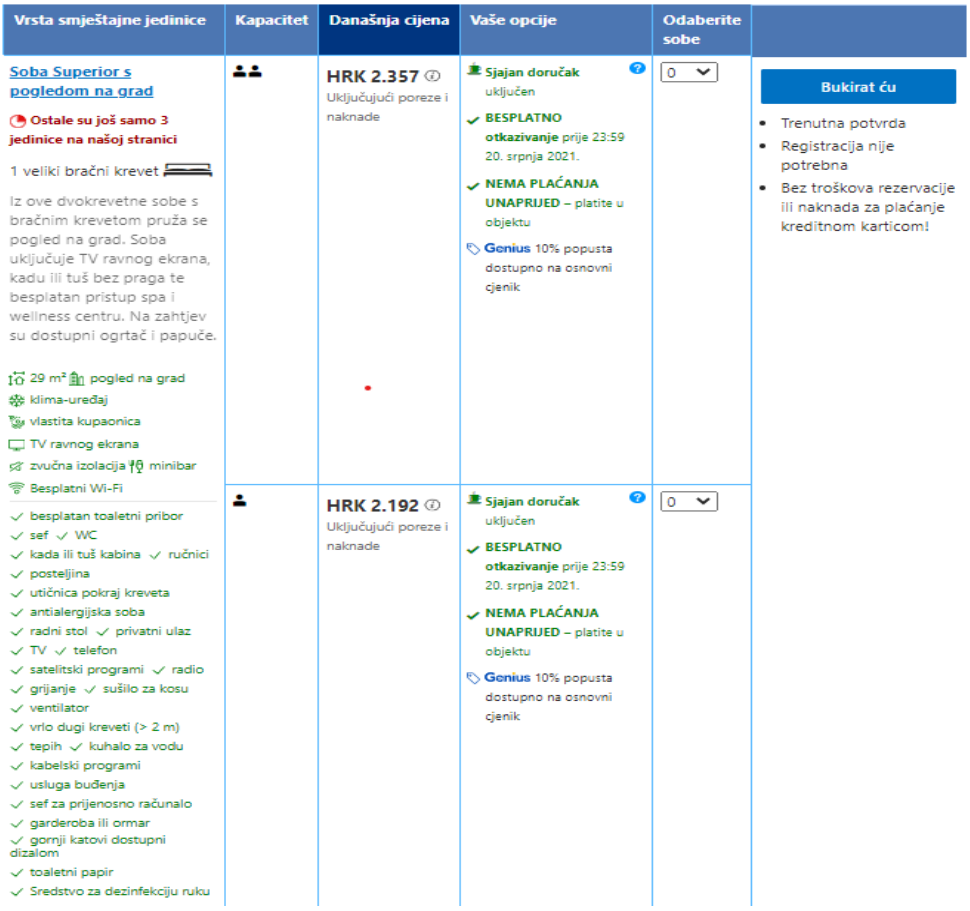

Source: Booking.com [21.7.2021.]

The data was collected from the official website of travel agency Booking.com where detailed description of room attributes is available for every room. Similar data sources were used by Thrane (2007), Andersson (2013) and Chen and Rothschild (2010). The data was collected on April 30, 2020 for hotels with available double rooms for two nights in period 1-3 July, 2020, in a period of high season. The period vas limited in order to obtain homogenous data sample. Total 56 hotels out of 65 ones satisfied this condition. Data was inserted manually in Excel.

5. DESCRIPTIVE STATISTICS

Table 1 presents descriptive statistics of discrete variables. The average prices is 3.486,61 kn, while the minimum price 1.376 kn and the maximum price is 8.141 kn. Number of stars range from 2 to 5, with an average of 3,79. Average hotel guest reviews ranges from 6,4 to 9,8 with the mean average hotel gest review of 8,452. The mean room surface is 24 m^2 with the minimum room surface is 16 m^2 and the largest room is of 45 m^2. The closest hotel room is located 100 m from the city center while the largest distance from the city center is 7,4 km. The average distances from the city center and from the beach are 0,9 km. The nearest hotel room to the beach is located 30 m far from it while the largest distance from the beach is 2,4 km.

Table 1. Descriptive statistics of discrete variables

		Price April 30	Number of stars	Guest review	Room surface (m^2)	Distance from the city (m)	Distance from the beach (m)
N	Valid	56	56	54	56	56	56
	Missing	0	0	2	0	0	0
Mean		3483,61	3,79	8,752	24,00	903,57	906,61
Mean std. Err.		180,38	,071	,1038	,809	166,222	69,761
Median		3185,00	4,00	8,900	23,00	500,00	950,00
Mode		3030,00	4	8,9	22	100	950[a]
Std. Deviation		1349,86	,530	,7625	6,054	1243,889	522,042
Variance		1822124,13	,281	,581	36,655	1547259,740	272528,279
Range		6765,00	3	3,4	29	7300	2370
Minimum		1376,00	2	6,4	16	100	30
Maximum		8141,00	5	9,8	45	7400	2400

Dummy variables are described in Table 2.

Table 2. Descriptive statistics of dummy variables

Dummy variable (yes = 1; no = 0)	Frequency of 1	Frequency of 0	Mean or %
Sea view	12	44	21,4
City view	28	28	50
Yard/garden view	15	41	26,8
Breakfast	48	8	85,7
Bathtub	37	19	66,1
Minibar	44	12	78,6
Robe and slippers	28	28	50
Swimming pool	14	42	25
Fitness	10	46	17,9
Spa/Wellness	25	31	44,6
Room service	39	17	69,6
Children allowed	52	4	92,9

Only 12 hotel rooms (21,4%) have a sea view while half of them have a city view. 15 hotel rooms have yard/garden view (26,8%). Majority of hotels offer breakfast included (85,7%). Other most frequent attributes are bathtub (66,1%), minibar (78,6%), room service (69,6%) children allowed (92,9%). Swimming pool access is present in 14 out of 56 hotels (25%), and fitness in 10 (17,9%). Half of hotel rooms involve robe and slippers, while 25 hotels (44,6%) offer spa/wellness.

6. RESULTS

Starting from initial model with 18 regressor variables, by application of stepwise method, variables without significance were eliminated and final log-linear model with four regressor variables was selected: X_1 – number of stars, X_2 – robe and slippers, X_3 – guest review, and X_4 – room surface. Y_i is room price.

$$logY_i = 5{,}640 + 0{,}29 \cdot X_{1i} + 0{,}189 \cdot X_{2i} + 0{,}111 \cdot X_{3i} + 0{,}011 \cdot X_{4i} \quad (2)$$

R^2 = 0,65; adjusted R^2 = 0,622; standard error σ_r = 0,228

F-test indicates that the suggested regression model is statistically significant. Detailed tests of parameter coefficients are presented in Table 3.

Table 3. Regression results of log-linear model

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
	B	Std. Error	Beta			Tolerance	VIF
(Constant)	5,640	,385		14,663	,000		
Number of stars	,290	,079	,420	3,654	,001	,540	1,853
Robe and slippers	,189	,072	,258	2,640	,011	,749	1,335
Guest review	,111	,049	,229	2,285	,027	,710	1,409
Room surface (m²)	,011	,005	,188	2,072	,044	,869	1,150

Parameter β_0 = 5,640 is a logarithm of room price in case that all explanatory variables take value zero. Since all the parameter values are small, and since it holds that $e^{\beta_k} \approx 1 + \beta_k$, the other parameters can be interprented as percentage changes in dependent variable. With additional star the room price increases by 29%. Price of rooms equipped with rope and slippers is 18,9% higher than price of rooms without this equipment. If guest review increases by 1, room price increases by 11,1%. Finally, if room surface increases by 1, the room price increases by 1,11%.

Regression model in standardized form is:

$$logY_i = 0{,}420 \cdot X_{1i} + 0{,}258 \cdot X_{2i} + 0{,}229 \cdot X_{3i} + 0{,}188 \cdot X_{4i} \quad (3)$$

Number of stars has the highest relative effect. Test of multicollinearity indicates that there is no problem of multicollinearity:

VIF_1 = 1,853 → VIF_1 < 5; TOL_1 = 0,540 → TOL_1 > 0,2
VIF_2 = 1,335 → VIF_2 < 5; TOL_2 = 0,749 → TOL_2 > 0,2
VIF_3 = 1,409 → VIF_3 < 5; TOL_3 = 0,710 → TOL_3 > 0,2

$VIF_4 = 1{,}150 \rightarrow VIF_4 < 5$; $TOL_4 = 0{,}869 \rightarrow TOL_4 > 0{,}2$

Durbin Watson test also indicates that there is no autocorrelation in the model. Spearman coefficient correlation tests shows that there is no coefficient which is statistically significant indicating that there is no problem of heteroscedasticity in the model. Statistical significance of all the coefficients is below 5% ($\alpha_1 = 0{,}010$; $\alpha_2 = 0{,}103$; $\alpha_3 = 0{,}081$; $\alpha_4 = 0{,}353$).

7. DISCUSSION

The presented statistical analysis which involved a stepwise method to select variables for the final model indicates which variables significantly define hotel room prices in Split. Distance from the city center turned out to be not significant and it is not included in the final model. This finding is not aligned with results of Andersson (2013), Chen and Rothschild (2010), Espinet et al. (2003) and Soler et al. (2019) who find that location of the hotel is statistically significant. Distance from the beach also turns to be not statistically significant and thus, not included in the final model.

Number of stars is statistically significant variable which is in line with the previous literature like Soler et al. (2019), Castroand and Ferreira (2015), Fleischer (2012) and Espinet et al. (2003) meaning that higher category of the hotel implies higher room prices. Sea view was not statistically significant in the initial model although Fleischer (2012) concluded that rooms with sea view are valued more. Presence of the bathtub turned to ben not significant attribute in the log-linear model which is in line with findings of Chen i Rotschild (2010). However, bathtub was a statistically significant variable in research of Andersson (2013)

Guest review was strongly significant attribute in Pavlinović and Radman (2017). Variable „rope and slippers“ was not present in the literature, but it affects significantly room price in this model. Room surface was significant variable in research of Andersson (2013) and the same finding was confirmed in this research.

8. CONCLUSION

Hedonic price function is not widely applied in tourism sector, however the existing literature provided a foundation to apply hedonic pricing model on analysis of hotel room attributes in city Split.

Surprisingly, location variables were not significant for the price formation which was in contrast to the most existing findings, but aligned with Pavlinović and Radman (2017). A strong significance of number of stars and guest reviews was in line with the existing findings. Also, the room size and rope and slippers were statistically significant attributes.

The main limitations of this research is relatively small and limited sample in terms of spatial and temporal dimensions. Thus, extension of the analysis to off-season period, as well as extension of sample to the region might bring more robust findings. Also, application of quantile regression models could make the research more relevant.

However, this is one of the rear applications of hedonic pricing in tourism sector in Croatia. Implications of this model may serve to investors and tourism managers in accommodation and

catering in order to improve their pricing strategy. The same analysis can be applied also to some other locations in Croatia since the results may vary depending on the region.

REFERENCES

[1] Agušaj, B., Bazdan, V., & Lujak, Đ. (2017). The relationship between online rating, hotel star category and room pricing power. Ekonomska misao i praksa, (1), 189-204.

[2] Andersson, F. (2013): Determining room rates in Sweden – A hedonic prices approach of the Stockholm hotel market, Lunds Universitet, Lund.

[3] Boras, T., Tica, J. (2013): Prostorna elastičnost traženih cijena stanova na stambenom tržištu Grada Zagreba, Serija članaka u nastajanju, 13-04, Sveučilište u Zagrebu, Ekonomski fakultet, Zagreb

[4] Binesh, F., Belarmino, A., & Raab, C. (2021). A meta-analysis of hotel revenue management. Journal of revenue and pricing management, 1-13.

[5] Cai, Y., Zhou, Y., & Scott, N. (2019). Price determinants of Airbnb listings: evidence from Hong Kong. Tourism Analysis, 24(2), 227-242.

[6] Castro, C., Ferreira F.A. (2015): Effects of Hotel Characteristics on Room Rates in Porto: a Hedonic Price Approach, AIP Conference Proceedings

[7] Champ, A., Boyle, K., Brown, T. [edited by] (2003): A Primer on nonmarket valuation, The economics of non-market goods and resources, 3, Springer Science+Business Media, New York

[8] Chica-Olmo, J., González-Morales, J. G., & Zafra-Gómez, J. L. (2020). Effects of location on Airbnb apartment pricing in Málaga. Tourism Management, 77, 103981.

[9] Chen, C.-F., Rothschild, R. (2010): An application of hedonic pricing analysis to the case of hotel rooms in Taipei, Tourism Economics, 16 (3), str. 685–694.

[10] Espinet, J.M., Fluvià, M., Rigall, R., Oliveras, A. (2017): Cruise tourism: a hedonic pricing approach, European Journal of Management and Business Economics, 27 (1), str. 101-122

[11] Espinet, J.M., Saez, M., Coenders, G., Fluvià, M. (2003): Effect on prices of the attributes of holiday hotels: a hedonic prices approach, Tourism Economics, 9 (2), str. 165-177.

[12] Fleischer, A. (2012): A Room with a View — A Valuation of the Mediterranean Sea View, 52nd Congress of the European Regional Science Association: "Regions in Motion – Breaking the Path", Bratislava

[13] Ivanov, S., & Zhechev, V. (2012). Hotel revenue management–a critical literature review. Tourism: an international interdisciplinary journal, 60(2), 175-197.

[14] Kim, J., Jang, S., Kang, S., & Kim, S. J. (2020). Why are hotel room prices different? Exploring spatially varying relationships between room price and hotel attributes. Journal of Business Research, 107, 118-129.

[15] Kunovac, D., Đozović, E., Lukinić, G., Pufnik, A. (2008): Primjena hedonističke metode za izračunavanje indeksa cijena nekretnina u Hrvatskoj, Istraživanja (I-20), Hrvatska narodna banka, Zagreb

[16] Mandić, A., Jurun, E. (2018): The Determinants of Small and Family Owned Hotel Room Rates, International Journal of Business and Economic Sciences Applied Research, 11 (2), str. 17-22.

[17] Mandić, A., Petrić, L. (2020): The impacts of location and attributes of protected natural areas on hotel prices: implications for sustainable tourism development, Environment, Development and Sustainability, 23, str. 833-863.

[18] Masiero, L., Heo, C. Y., & Pan, B. (2015). Determining guests' willingness to pay for hotel room attributes with a discrete choice model. International Journal of Hospitality Management, 49, 117-124.
[19] Nelson, K. M., Partelow, S., Stäbler, M., Graci, S., & Fujitani, M. (2021). Tourist willingness to pay for local green hotel certification. Plos one, 16(2), e0245953.
[20] Pavlinović Mršić, S., Radman, L., 2017. Utjecaj udaljenosti od Dioklecijanove palače na cijenu noćenja: Primjena hedoničke metode, u Dobrinić, D. (ur.), Book of Papers of 2nd Croatian Direct Marketing Association Conference (CRODMA), Theme: Customer Relationship Management, The impact of digital technology; Varaždin, 12.-13. listopada 2017, CRODMA, Varaždin, str. 175.-187.; http://crodma.hr/wp-content/uploads/2017/11/CRODMA-PROCEEDINGS-1.pdf
[21] Sanchez-Lozano, G., Pereira, L. N., & Chavez-Miranda, E. (2021). Big data hedonic pricing: Econometric insights into room rates' determinants by hotel category. Tourism Management, 85, 104308.
[22] Sánchez-Pérez, M., Illescas-Manzano, M. D., & Martínez-Puertas, S. (2019). Modeling hotel room pricing: A multi-country analysis. International Journal of Hospitality Management, 79, 89-99.
[23] Soler, I., Gemar, G., Correia, M., Serra, F. (2019): Algarve hotel price determinants: A hedonic pricing model, Tourism Management, 70 (str. 311-321)
[24] Thrane, C. (2007): Examining the determinants of room rates for hotels in capital cities: The Oslo experience, Journal of Revenue & Pricing Management, 5, str. 315-323
[25] Tietenberg, T., Lewis, L. (2015): Environmental & Natural Resource Economics, 10. izdanje, Pearson Education Limited, Harlow, Engleska
[26] Zhang, Z., Qiang, Y., Law, R. (2011): Determinants of hotel room price, An exploration of travelers' hierarchy of accommodation needs, International Journal of Contemporary Hospitality Management, 23 (7), str. 972-982

Preliminary communication / Prethodno priopćenje

READINESS OF DEVELOPING ECONOMIES' BANKING SECTORS FOR AI-ENHANCED SERVICES: THE EXAMPLE OF THE BANKING SECTOR IN BOSNIA AND HERZEGOVINA

TAMARA TURNADŽIĆ
University of Sarajevo
School of Economics and Business
Trg oslobođenja - Alija Izetbegović 1, 71000 Sarajevo, Bosnia and Herzegovina
tamara.turnadzic@gmail.com

ALMIR PEŠTEK, PhD
University of Sarajevo
School of Economics and Business
Trg oslobođenja - Alija Izetbegović 1, 71000 Sarajevo, Bosnia and Herzegovina
almir.pestek@efsa.unsa.ba

MERIMA ČINJAREVIĆ, PhD
University of Sarajevo
School of Economics and Business
Trg oslobođenja - Alija Izetbegović 1, 71000 Sarajevo, Bosnia and Herzegovina
merima.cinjarevic@efsa.unsa.ba

ABSTRACT

In times when AI's progress and popularity seem to grow by the second, this paper explores what it can do for the banking industry. The qualitative research behind it strives to determine banks' abilities to deploy and use AI in ways that will add value to the bank, especially in developing economies. The research was conducted in the Federation of Bosnia and Herzegovina (B&H). Nine interviewees from seven banks (representing the majority of the bank industry) participated in semi-structured interviews, with the goal of addressing six main research questions. The research shows that B&H banks fall into the category of digital laggards, and explores the challenges they are facing in their path towards technological innovativeness – the main one being the restrictions put on by regulators and the government. Besides challenges, the research participants discussed AI use cases, motives for (considering) introducing AI into their operations, impact to employees as well as impact to client communication. The research highlights the perceptions around clients' readiness for non-human communication in retail banking, concluding that it depends on the service type, as well as age, education, IT experience, location, culture, general openness to innovation, trust, and risk aversion (typical of post-conflict societies).

KEYWORDS: Artificial intelligence (AI), Machine learning (ML), Banking, Technology readiness

1. INTRODUCTION

Each industry can benefit from AI in different ways and find specific ways of using it, from process improvement to cost efficiency. Banking is no exception, but it is interesting due to its infamously slow adoption of new technology. Banking is not an industry known for innovation leaps or significant shifts in the dynamic of players participating. Mergers and acquisitions in banking are not really comparable in scope with, for example, the shifts from the telegraph to the telephone (and later on to mobile) in telecommunications [King, 2014]. As quoted by Lumley (2022), during the financial crisis in 2009, Paul Volcker, former US Federal Reserve chief, criticized the banking industry and memorably said that 'the ATM has been the only useful innovation in banking for the past 20 years'.

As one of the most relevant players in the world of technology, Microsoft [2018] argues that 'reimagining and simplifying business processes will give financial institutions the edge they need to compete in the rising digital economy while improving their bottom lines. AI is not going to replace bankers. It will optimize how banks work by helping them become more agile, make smarter decisions, and, ultimately, stay more competitive.' It is hard to find a recognized consultancy that has not published a report on AI's potential transformative power in banking. KPMG [2016], for example, envisions an 'invisible bank', with 'enlightened virtual assistants' in replacement of people in all aspects of customer interaction.

Mustak et al. [2021] argue that 'using AI without understanding its mechanisms is likely to result in detrimental consequences, so endeavors should be made, along different directions, to enrich key constructs and theoretical insight'.

While it is undeniably important to gain more insight into the customers' point of view, this paper strives to determine banks' abilities to deploy and use AI in ways that will add value to the bank, especially in developing economies.

This paper will start with listing research objectives and explaining the methodology. After that, research insights will be detailed, before providing a conclusion and noting limitations.

2. RESEARCH ANALYSIS AND RESULTS

2.1. OBJECTIVES

This research aims to provide answers to the following questions:

RQ1: How do banks perceive their level of digital innovativeness?

RQ2: Are banks actively working on integrating AI into their service model?

RQ3: What are the motives for introducing AI into banking operations?

RQ4: What challenges are banks facing in this regard, and what challenges do they expect to face in the future?

RQ5: What do banks perceive as key factors for the successful implementation of AI in customer service?

RQ6: How do banks perceive the customer’s readiness for AI in banking?

2.2. METHODOLOGY

The author opted for semi-structured interviews as they offer more versatility and flexibility in qualitative inquiries [Kallio et al., 2016]. More precisely, semi-structured interviews are open discussions about predefined themes with the possibility of adding or excluding themes from the interview scenario as the interview proceeds. The interviews were conducted with decision makers in banks (primarily targeting marketing managers). In qualitative research design, the sample size is determined by the principle of completeness, which suggests that more interviews should be conducted if they add new insights or perspectives to the scope of the results [Rubin & Rubin, 1995]. Since, as of 2022, there were 22 commercial banks in Bosnia and Herzegovina (6 of which are under the same parent company); the goal was to conduct semi-structured interviews until the point of saturation.

Nine interviewees from seven leading banks in Bosnia and Herzegovina participated in the semi-structured interviews. The interviews were conducted between January and June of 2022, and lasted between 30 and 60 minutes each. The below table lists the position the interviewees held in a given bank at the time of the interview. The interviews were held online, using Microsoft Teams. All interviews were recorded, of which the participants were informed beforehand.

Table 1: Research participants' overview

Bank	**Number of participants**	**Position of participant(s)**
Bank #1	1	Marketing Manager
Bank #2	2	Head of PR and Marketing Communication Department; Head of Multichannel & Digital Marketing Department
Bank #3	2	Head of Marketing&PR; Customer Relationship Management Specialist
Bank #4	1	Electronic Channels Project Specialist
Bank #5	1	Head of Digital Banking Center; President of the Digital Banking Committee under Banks Association of Bosnia and Herzegovina (BABiH)
Bank #6	1	Head of CX, Marketing and Communication
Bank #7	1	Head of Digital Marketing

While the format of the interview was semi-structured, an outline of basic questions was created beforehand. These questions were asked in no specific order, and the conversations expanded to other topics as well. The questions were formed based on a thorough literature review that is not part of this paper due to format constraints. It included over 200 sources (books, papers, reports), and a few examples are Al-Somali et al. [2009], Anandarajan et al. [2000], Avkiran [1999], Ball et al. [2017], Belanche et al. [2019], Cabrera-Sánchez et al. [2020], DeCanio [2016], Fares et al. [2022], Fernandes & Oliveira [2021], Gursoy et al. [2019], Holmström

[2022], Hund at al. [2021], Luo et al. [2019], Manch & Shankaranarayanan [2020], Mhlanga [2020], Moutinho Smith [2000], Mustak et al. [2021], Noreen et al. [2023], Plastino, & Purdy [2018], Rai et al. [2019], Robinson et al. [2019], Sheth et al. [2022], Trivedi [2019], Wirtz et al [2018], Xu et al. [2020].

The interviews were subsequently coded to highlight important themes.

2.3. AI IN BOSNIAN-HERZEGOVINIAN BANKING

When it comes to the first research question, *('How do banks perceive their level of digital innovativeness?'*), almost all Bosnian-Herzegovinian banks see themselves as digitally advanced; many go as far as describing themselves as leaders in this area. Economist Impact's survey [2022] showed that banking executives around the world highlight the digitalization of financial services and the adoption of emerging technologies as the key trends for the industry over the next decade. Bosnian-Herzegovinian banking executives are similarly aware of the importance of digitalization and are investing into digital campaigns. Most are aiming to combine digital banking with traditional banking. However, they still predominantly use legacy systems, making the process considerably slower. Digital transformation is therefore a difficult and lengthy process, but overall perceived as absolutely worth the time and effort. Only one of the participating banks offered a somewhat different perspective: they believe it is difficult to implement digitalization in a country that still requires clients' physical presence for completion of most banking services. While there is notable awareness of the importance of digitalization, as well as efforts to increase it, there are no significant investments into latest technology, starting with AI and ML, which Singh [2022] describes as the 'flagbearer of this contemporary digital transformation', and many other sources agree. When it comes to measuring digitalization / digital innovativeness / digital transformation efforts, there are many different KPIs to consider. Yanushefski [2023] summarizes the basic KPIs for digital banking efforts: new account applications and activations; transactions by channel (in-person vs. digital); online banking logins by device; login frequency (daily, weekly, and monthly) and retention; call center volume; and Customer sentiment (CSAT[1] or NPS[2]). The majority of banks interviewed track at least some of these. Malik [2022] lists ten digital transformation KPIs to track, many of which, based on the interviews conducted for this research, are not tracked in Bosnia-Herzegovinian banks. Examples are employee productivity, percentage of AI-enabled business, reliability and availability (popular metrics include uptime[3], MTTF[4], MTTR[5], and MTBF[6]), and percentage of cloud deployments. Fitzpatrick & Strovink [2021] list five basic metrics for digital progress – return on digital investments, percentage of annual technology budget spent on bold digital initiatives, time required to build a digital application, percentage of business leaders' incentives linked to value-creating digital builds, and top technical talent being attracted, promoted, and retained. Bosch and BearingPoint Institute [2015] offer a simple categorization of banks (in terms of their digital efforts): digital leaders, digital shy, and digital laggards, with three levels:

- 'low (legacy systems are predominant and several processes are paper-based and/or performed manually),

1 CSAT stands for Customer Satisfaction.

2 NPS stands for Net Promoter Score.

3 Uptime is the time a piece of equipment or software is functioning.

4 Mean time to failure is the amount of time an asset operates before it fails.

5 Mean time to resolve is the amount of time it takes to resolve a failure.

6 Mean time before failure is the time between failures.

- intermediate (majority of processes are automated and online),

- high (they have a high degree of automation and digitization. The internet, intranet, mobile apps and mobile phones are central to their businesses. Their work culture encourages digital innovation and continual improvement).'

Based on the interviews conducted in this research, Bosnian-Herzegovinian banks fall into the low category, meaning they are classified into digital laggards. Bosch [2015] describes these banks as 'regional banks and local branches of foreign banks', and banks that are passive in their use of digital technology. This is in line with Deloitte's Digital Banking Maturity report [2022]: out of 40 surveyed banks in the region (B&H, Bulgaria, Croatia, Serbia, Slovenia), 88% are considered digital latecomers and digital adopters. The remaining 12% are smart followers or digital leaders. Bosnian-Herzegovinian banks rank best when it comes to available information on internet platforms and public websites. There is room for improvement when it comes to mobile platforms. In regards to future investments, the biggest potential is in more advanced everyday banking functionalities that improve customer experience, including but not limited to: personal data management through digital platforms, chatbots, and managing personal finances. In short, the conclusions from this research are in line with those from the abovementioned survey conducted by Bosch and BearingPoint Institute - 'there is a big gap between banks' rhetoric about digitization and their actions'.

The conclusions around the second research question ('*Are banks actively working on integrating AI into their service model?'*) are in line with the categorization of digital laggards: Bosnian-Herzegovinian banks do not currently have AI implemented into their service model, and have not shared clear steps on doing this. Only one participating bank was recognized as having more concrete, clear plans on how to increase the use of AI/ML.

When it comes to motives for introducing AI (third research question: '*What are the motives for introducing AI into banking operations'?*), research participants listed revenue increase, cost decrease, increased efficiency, better customer experience and quality of service, protection from cyberattacks, increased employees' productivity, and brand image / marketing. The impact of AI on revenue and cost is inconclusive – depending on the research, conflicting conclusions can be drawn. McKinsey's research [2020] shows that 'revenue increases from AI adoption are more commonly reported in half of business functions, but cost decreases are less common'. The research also showed that 22% of those surveyed 'maintain that at least 5% of their profits can be attributed to the introduction of AI into their business'. However, in their article for McKinsey, Biswas et al. [2020] claim that AI can help increase revenue 'through increased personalization of services to customers (and employees); lower costs through efficiencies generated by higher automation, reduced errors rates, and better resource utilization; and uncover new and previously unrealized opportunities based on an improved ability to process and generate insights from vast troves of data.' When it comes to efficiency and employee's productivity, while AI can definitely be helpful, there are prerequisites. The findings of Fares et al. [2022] 'indicate the effectiveness of AI tools in driving efficient organizational strategies' – but there are challenges to consider, 'including the human resources aspect and the organizational culture to allow for such efficiencies'. Fountaine et al. [2019] concluded the same for Harvard Business Review, by naming culture as the biggest challenge over technology. Their research shows that for the majority of 'businesses that are not born digital, traditional mindsets and ways of working run counter to those needed for AI.' Blanding [2018] agrees that AI is not guaranteed to boost productivity, and quotes Prithwiraj (Raj) Choudhury, assistant professor at Harvard Business School, who said: 'If someone's past experience has been entirely in the world of older technology, and suddenly a machine learning tool is thrust upon

them, they will be less productive, even if the tool is a great tool.' This viewpoint is interesting for both perspectives (banks and their clients). Culture needs to catch up with technology before better customer experience and quality of service can be achieved. Better customer experience, starting with personalization, is 'increasingly powered by AI', according to Edelman & Abraham [2022]. Businesswire's research [2023] showed that customers agree - 73% of them think that AI can have a positive impact on their experience. Choithani et al. [2022) see AI as a great booster of security. The European Banking Federation (n.d.) sees enhancing security and risk control as one of the great opportunities AI provides. As many other authors, Mhlanga, D. [2020] agrees, and recommends 'that financial institutions and non-financial institutions and governments across the world adopt and scale up the use of AI'. However, it is not that simple, as many other sources warn that AI/ML usage in banking could be a double-edged sword. Vanderford [2022] warns ML models could be an unexpected 'avenue for attacks', since 'the protection of machine learning remains in its infancy, putting the institutions that use them at considerable risk'. Introducing ML into any software infrastructure brings about new attack surfaces and new way to disrupt systems. Violino [2022] acknowledges that AI is playing a bigger role in cybersecurity, but reminds that hackers can use that benefit as well. When it comes to using AI for brand image / marketing, Ho and Chow's research [2023] 'confirms the significant impact of AI marketing efforts (information, accessibility, and customization) on brand experience and brand preference, in addition to the effect of brand preference on repurchase intention'. There are other studies that show a positive correlation between AI and branding [Trivedi, 2019; West et al., 2018], but there are also those that point to the IT paradox: the claim that IT has become a necessity rather than an option to gain competitive advantages [Hajli et al., 2015; Seric et al., 2016].

When it comes to challenges (*'What challenges are banks facing in this regard, and what challenges do they expect to face in the future?'*), all but one interviewed banks agree: restrictions put on by regulators and the government are the main challenge faced. Other challenges noted by research participants were finding technical staff in the local market, which is not surprising for a small country with concerning statistics around human capital flight (according to UNFPA – United Nations Population Fund [2021], almost half of B&H youth had been thinking about leaving the country). Another challenge mentioned was the balancing act between European laws (as most B&H banks are part of EU-based banking groups) and local laws. If Bosnia and Herzegovina's application for European Union is ever granted, it will mean GDPR compliance is required – and any data collected before that point might not be legally usable going forward. The interviewees focused on local challenges; for comparison, some of the general barriers to the wider adoption of AI within organizations are noted in The Economist's research [2020] are cost, insufficient infrastructure, insufficient data, lack of appropriately skilled staff, and lack of awareness of AI use cases among senior management. Most of these were mentioned by interviewees in this research as well.

When it comes to the impact that introducing AI/ML technology will have on employees, for now, banks do not see this as a major issue. They expect retraining, as opposed to layoffs and new hiring. However, it is important for banks to keep in mind this will not happen on its own. According to a report by Accenture [2018], bank leaders 'recognize that intelligent technologies are reshaping the core banking process and can transform customer experiences', but 'few plan to significantly increase investments in reskilling their workforces to enable these technologies in the near-term'. Both pessimist and optimist outlooks on topic can be found. Kelly [2023] highlights that Goldman Sachs predicts 300 million jobs will be lost or degraded by AI. On the other hand, many believe that it comes down to properly preparing. In their popular book on economists' perceptions on prediction machines, Agrawal et al. [2018] note that there is no

immediate or near-future risk to human jobs – AI and humans work best in parallel. They go on to explain that 'automation that eliminated a human from a task does not eliminate them from a job'. DBS, a Singaporean bank (that won numerous awards, such as Best Bank in the World 2022 by Global Finance) has an upskilling and reskilling program in progress, and believes it to be a path to future-proof workforce. However, getting retrained requires time, so Agrawal et al. [2018] conclude that an 'AI-induced recession is not out of the question'.

As for key factors for successful implementation of AI in customer service, banks listed improved service, proactiveness (by both the banks and the regulator), as well as simply - time and patience.

It is useful to note here that there are useful frameworks companies (including banks) could use to assess their AI readiness. One example is the framework detailed by Holmström [2022], that assesses an organization's ability to use AI technologies for digital transformation, in four key dimensions: technologies, activities, boundaries, and goals.

All of this brings us to the final research question, the most closely related to the overall research topic and therefore potentially the most interesting ('How do banks perceive the customer's readiness for AI in banking?'). Bosnian-Herzegovinian banks agree that their clients still value human touch in service encounters. The key conclusion is that the value put on human touch is strongly dependent on the type of service in play. This is something that Wirtz at al. [2018] addressed through their research of service robots. To assess whether a robot or a human would be the preferred service provider, they considered task from a cognitive/analytical and emotional/social aspects, while also considering their level of complexity. Depending on the type of service, banking tasks could be considered as a combination of complex cognitive/analytical and simple emotional/social tasks (for which robots are a 'better' service provider), and a combination of complex cognitive/analytical and complex emotional/social tasks (for which humans are a 'better' service provider).

Fahy [2021) shared the results of research done by UK's Cynergy Bank, that shows 'an overwhelming desire for a blend' between technology and human interaction. While the research focused on digital functionality in general, instead of AI specifically, some of its conclusions are relevant for this paper as well, such as:

- 'Over three-quarters of SMEs (78 percent) agree that a digital transformation of banking needs to be balanced with a human element, with those in the over-55 age group agreeing most strongly at 81 percent compared with 78 percent in the 18-34 age group and 76 percent in the 35-54 age group.
- When asked to rank their most desired banking service, unsurprisingly, "24/7 access to customer service via an app with human contact" appeared near the top of the list, with 29 percent of SMEs citing this as a service they would require if they were to move all business banking needs to digital-only services.'

According to research participants, age, education, IT experience, location, culture, and general openness to innovation are also important factors. Factors of age, location, and IT experience were explored in many previous research papers. Chu et al. [2022] wrote a paper on digital ageism, focusing on AI challenges and opportunities from the perspective of older population. They highlight that older adults have both less access to technology and less support to learn new technology. Ball et al. [2017] support this, describing older adults as 'the most digitally divided demographic group', 'digital immigrants', and 'physical natives' (whereas younger generations are 'digital natives'). König et al. [2018] researched Internet usage among older

Europeans (≥ 50). While the research showed that 49% of them use the Internet, the results varied greatly among different countries. Along with individual indicators, like age, gender, and social class, 'results indicate that previous experience with computers during one's time in the workplace is positively associated with Internet use in old age. Furthermore, use of the Internet among an individual's social network positively influences their use.' Then there is the role of trust, or inversely put the role of security concerns, especially since banking is intimately connected to the sensitive topic of money. Most survey participants agree the client's willingness to use technology will differ greatly depending on what the service is. The role of trust in both banking and in using AI in general was researched by many. The research conducted by Noreen at al. [2023] concludes that people are not ready to take risks, especially when it comes to financial matters. Same as with this paper, they focused part of their research on developing countries, and concluded that AI 'is a new technology and very few people in developing countries know about it', which negatively influences technology adoption. They also believe that the hesitation in the adoption of AI will be lessened by increasing awareness around it. The client's 'ability to understand and use AI-based financial services tends to have a positive effect on the adoption of digital banking services'. This research also showed a significant difference in the intentions to adopt AI depending on location (underdeveloped countries generally do not have the resources to invest heavily into technology, so they do not invest into increasing the people's awareness either, making them less likely to adopt new technology) and education (highly educated clients are more likely to adopt AI in banking services). KPMG's research [2023] is somewhat contradictory to this: according to them, Western countries and Japan 'generally have lower trust and less positive attitudes than people in the emerging economies', and are less convinced of the benefits of AI. Other key insights are:

- 'Fewer people in Western countries, Japan, South Korea and Israel view current laws and regulations for safeguarding AI as sufficient, and report less confidence in companies to develop, use and govern AI.'
- 'People in Western countries generally report less use of AI at work, and lower use and knowledge of AI in common applications'.

The reasons likely lie in the nature of economies we consider emerging: this can encourage a 'growth mindset in relation to the acceptance of technology'. They conclude that trust and acceptance depend on the AI application, and that cybersecurity is perceived as the top risk globally.

Writing for Forbes, Towers-Clark [2019] comments on the research that showed 80% of UK respondents do not trust AI when it comes to money. And while any technology takes time to adopt and gain the trust of users, AI has the added disadvantage of being very hard to explain. In general, humans seem to be comfortable with AI making them more efficient (comfortable with, for example, AI running analysis to get them faster treatment, better products, or better suggestions) – as long as they are making the decisions, and AI is simply doing things they do not have the time to do. When AI starts to make judgement calls on their behalf, it is a very different story. 'A lot of the fears around AI come down to a general lack of understanding of how AI works and what its limits are', which is something that three participating banks pointed out within this survey as well. 'The social responsibility of companies and governments to educate the public on AI has become an increasingly pertinent question'. He concludes that 'money might be a sensitive subject, and perception of the banking sector has definitely soured over the last decade, but the ability of AI to find new efficiencies could make a massive difference to people struggling to make ends meet. There has been a lot of talk about the

wonders AI will perform in the business world, but the long-term success of AI, as with many new technologies, will ultimately be decided by ordinary people and the health of their wallets.'

When it comes to the low trust and risk-aversion, that most of the interviewees notice in Bosnian&--Herzegovinian banking clients, it is important to note the fact that Bosnia & Herzegovina is a post-war country. Muminovic and Efendic [2022] explored the long-term effects of war exposure on generalized trust and risk attitudes. They reference previous research that showed that 'childhood war experiences have long-lasting effects on financial risk-taking' and go on to conclude that 'that individuals living in municipalities with greater war fatalities report significantly higher distrust in people and simultaneously express greater risk aversion'. Risk is an important factor in making any financial decision and impacts many other areas, including investment behavior and technology adoption [Brown et al., 2018].

3. CONCLUSION AND RESEARCH LIMITATIONS

The overall research sentiment is that Bosnian-Herzegovinian banks know very little about the potential use cases (as well as benefits and challenges) of AI in banking. The level of current implementation, as of 2023, is minimal to none.

Besides the general limitations of interviewing as a research technique (some of which were mentioned before), the author acknowledges the limited geographical scope of our study. All banks participating in this research are located in Federation of Bosnia and Herzegovina. Even though many are part of banking groups with offices in the entity of Republika Srpska, which usually means common strategic goals, further research should include interviewees from RS banks. Additionally, further research should extend to the region, to be able to make cross-country comparisons.

REFERENCES

[1] Accenture (2018, May 02). Banks Must Invest in Reskilling Their Workforces to Seize AI-driven Growth Opportunities, Accenture Report Finds. https://newsroom.accenture.com/news/banks-must-invest-in-reskilling-their-workforces-to-seize-ai-driven-growth-opportunities-accenture-report-finds.htm

[2] Agrawal, A., Gans, J., Goldfarb, A. (2018). Prediction Machines: The Simple Economics of Artificial Intelligence. Harvard Business Review Press.

[3] Al-Somali, S. A., Gholami, R., & Clegg, B. (2009). An investigation into the acceptance of online banking in Saudi Arabia. Technovation, 29(2), 130–141. doi:10.1016/j.technovation.2008.07.004

[4] Anandarajan, M., Igbaria, M., & Anakwe, U. P. (2000). Technology acceptance in the banking industry. Information Technology & People, 13(4), 298–312. doi:10.1108/09593840010359491

[5] Avkiran, N.K. (1999). Quality customer service demands human contact. International Journal of Bank Marketing.

[6] Ball, C., Francis, J., Huang, K.-T., Kadylak, T., Cotten, S. R., & Rikard, R. V. (2017). The Physical–Digital Divide: Exploring the Social Gap Between Digital Natives and Physical Natives. Journal of Applied Gerontology. doi:10.1177/0733464817732518

[7] Belanche, D., Casaló, L. V., & Flavián, C. (2019). Artificial Intelligence in FinTech: understanding robo-advisors adoption among customers. Industrial Management & Data Systems. doi:10.1108/imds-08-2018-0368

[8] Biswas, S., Carson, B., Chung, V., Singh, S., & Thomas, R. (2020, Sep 19). AI-bank of the future: Can banks meet the AI challenge?. https://www.mckinsey.com/industries/financial-services/our-insights/ai-bank-of-the-future-can-banks-meet-the-ai-challenge

[9] Blanding, M. (2018, Mar 21). Why Artificial Intelligence Isn't a Sure Thing to Increase Productivity. https://hbswk.hbs.edu/item/artificial-intelligence-tools-won-t-automatically-increase-productivity?cid=wk-rss

[10] Bosch (2015). Digital banking: is your bank a leader or laggard?. https://www.bearingpoint.com/en/insights-events/insights/digital-banking-is-your-bank-a-leader-or-laggard/

[11] Brown, R., Montalva, V., Thomas, D., & Velásquez, A. (2018). Impact of Violent Crime on Risk Aversion: Evidence from the Mexican Drug War. The Review of Economics and Statistics. doi:10.1162/rest_a_00788

[12] Businesswire. (2023, Jan 31). 73% of Consumers Believe AI can have a Positive Impact on their Customer Experience. https://www.businesswire.com/news/home/20230131005091/en/73-of-Consumers-Believe-AI-can-have-a-Positive-Impact-on-their-Customer-Experience

[13] Cabrera-Sánchez, J-P., Villarejo-Ramos, A.F., Liébana-Cabanillas, F., Shaikh, A.A. (2020). Identifying relevant segments of AI applications adopters – Expanding the UTAUT2's variables. Telematics and Informatics. doi: 10.1016/j.tele.2020.101529

[14] Choithani, T., Chowdhury, A., Patel, S., Patel, P., Patel, D., Shah, M. (2022). A Comprehensive Study of Artificial Intelligence and Cybersecurity on Bitcoin, Crypto Currency and Banking System. Annals of Data Science. https://doi.org/10.1007/s40745-022-00433-5

[15] Chu, C.H., Nyrup, R., Leslie, K., Shi, J., Bianchi, A., Lyn, A., McNicholl, M., Khan, S., Rahimi, S., & Grenier, A. (2022). Digital Ageism: Challenges and Opportunities in Artificial Intelligence for Older Adults. The Gerontologist, Volume 62, Issue 7, Pages 947–955. https://doi.org/10.1093/geront/gnab167

[16] DBS. (n.d.). Upskilling and reskilling for a future-proof workforce. https://www.dbs.com/media/upskilling-reskilling/upskilling-and-reskilling-for-a-future-proof-workforce.page

[17] DeCanio, S. J. (2016). Robots and humans – complements or substitutes?. Journal of Macroeconomics, 49, 280–291. doi: 10.1016/j.jmacro.2016.08.003

[18] Deloitte. (2022). https://www2.deloitte.com/rs/en/pages/about-deloitte/articles/digital-banking-maturity-2022.html

[19] Economist Impact. (2022). Banking in 2035: global banking survey report. Retrieved from https://www.sas.com/en/whitepapers/banking-in-2035-global-banking-survey-report-113203.html?utm_source=google&utm_medium=cpc&utm_campaign=rsk-gen-gbc-edn-emea&gclid=Cj0KCQjwgLOiBhC7ARIsAIeetVDmIvQQaLTYmz6p3Va_h_1JbdCwfM_8sSCX1HIfROXAK_cX0Awh64QaArtmEALw_wcB

[20] Edelman, D.C., & Abraham. M. (2022). Customer Experience in the Age of AI. https://hbr.org/2022/03/customer-experience-in-the-age-of-ai

[21] Fahy, N. (2021, Sep 07). Digital banking with the human touch. https://internationalbanker.com/banking/digital-banking-with-the-human-touch/

[22] Fares, O.H., Butt, I. & Lee, S.H.M. (2022). Utilization of artificial intelligence in the banking sector: a systematic literature review. Journal of Financial Services Marketing. https://doi.org/10.1057/s41264-022-00176-7
[23] Fernandes, T., & Oliveira, E. (2021). Understanding consumers' acceptance of automated technologies in service encounters: Drivers of digital voice assistants adoption. Journal of Business Research, 122, 180–191. doi:10.1016/j.jbusres.2020.08.058
[24] Fitzpatrick, M. & Strovink, K. (2021, Jan 29). How do you measure success in digital? Five metrics for CEOs. https://www.mckinsey.com/business-functions/mckinsey-digital/our-insights/how-do-you-measure-success-in-digital-five-metrics-for-ceos
[25] Fountaine, T., McCarthy, B., & Saleh, T. (2019). Building the AI-Powered Organization. Retrieved from https://hbr.org/2019/07/building-the-ai-powered-organization
[26] Gursoy, D., Chi, O. H., Lu, L., & Nunkoo, R. (2019). Consumers acceptance of artificially intelligent (AI) device use in service delivery. International Journal of Information Management, 49, 157–169. doi:10.1016/j.ijinfomgt.2019.03.008
[27] Hajli, M., Sims, J. M., and Ibragimov, V. (2015). Information technology (IT) productivity paradox in the 21st century. International Journal of Productivity and Performance Management.
[28] Ho, S.P.S., Chow, M.Y.C. (2023). The role of artificial intelligence in consumers' brand preference for retail banks in Hong Kong. Journal of Financial Services Marketing. https://doi.org/10.1057/s41264-022-00207-3
[29] Holmström, J. (2022). From AI to digital transformation: The AI readiness framework. Business Horizons, Volume 65, Issue 3. https://doi.org/10.1016/j.bushor.2021.03.006
[30] Hund, A., Wagner, H.T., Beimborn, D., & Weitzel, T. (2021). Digital innovation: Review and novel perspective. The Journal of Strategic Information Systems. doi: 10.1016/j.jsis.2021.101695
[31] Kallio, H., Pietilä, A.M., Johnson, M., Kangasniemi, M. (2016). Systematic methodological review: developing a framework for a qualitative semi-structured interview guide. Adv Nurs, 72(12):2954-2965. doi: 10.1111/jan.13031.
[32] Kelly, J. (2023, Mar 31). Goldman Sachs Predicts 300 Million Jobs Will Be Lost Or Degraded By Artificial Intelligence. https://www.forbes.com/sites/jackkelly/2023/03/31/goldman-sachs-predicts-300-million-jobs-will-be-lost-or-degraded-by-artificial-intelligence/?sh=4ee79672782b
[33] King, B. (2014). Breaking Banks: The Innovators, Rogues, and Strategists Rebooting Banking. John Wiley & Sons.
[34] König, R., Seifert, A., & Doh, M. (2018). Internet use among older Europeans: an analysis based on SHARE data. Universal Access in the Information Society, 17(3), 621–633. doi:10.1007/s10209-018-0609-5
[35] KPMG. (2016). Meet Eva - Your Enlightened Virtual Assistant and the future face of the Invisible Bank. Retrieved from https://assets.kpmg/content/dam/kpmg/ke/pdf/rc/ita/meet-eva-future-of-the-invisible-bank.pdf
[36] KPMG (2023). Trust in Artificial Intelligence. Retrieved from https://kpmg.com/au/en/home/insights/2023/02/trust-in-ai-global-insights-2023.html
[37] Lumley, L. (2022, Oct 03). RIP the humble ATM?. https://www.thebanker.com/RIP-the-humble-ATM-1664785916
[38] Luo, X., Tong, S., Fang, Z., & Qu, Z. (2019). Frontiers: Machines vs. Humans: The Impact of Artificial Intelligence Chatbot Disclosure on Customer Purchases. Marketing Science. doi:10.1287/mksc.2019.1192
[39] Malik, P. (2022, May 05). 10 Digital Transformation KPIs and Metrics to Track (2023). https://whatfix.com/blog/digital-transformation-metrics/

[40] Mancha, R., & Shankaranarayanan, G. (2020). Making a digital innovator: antecedents of innovativeness with digital technologies. Information Technology & People, 34(1), 318–335. doi:10.1108/itp-12-2018-0577
[41] McKinsey&Company. (2020). The state of AI in 2020. Retrieved from https://www.mckinsey.com/Business-Functions/McKinsey-Analytics/Our-Insights/Global-survey-The-state-of-AI-in-2020#
[42] Mhlanga, D. (2020). Industry 4.0 in Finance: The Impact of Artificial Intelligence (AI) on Digital Financial Inclusion. International Journal of Financial Studies, 8(3), 45. doi:10.3390/ijfs8030045
[43] Microsoft. (2018). Banking on AI: Learn how AI is enabling the transformation of banking and capital markets. Retrieved from http://info.microsoft.com/rs/157-GQE-382/images/EN-CNTNT-eBook-BankingonAI.pdf
[44] Moutinho, L. and Smith, A. (2000). Modelling bank customer satisfaction through mediation of attitudes towards human and automated banking. International Journal of Bank Marketing, Vol. 18 No. 3, pp. 124-134. doi: 10.1108/02652320010339699
[45] Muminovic, A. & Efendic, A.(2022). The long-term effects of war exposure on generalized trust and risk attitudes: evidence from post-conflict Bosnia and Herzegovina. Southeast European and Black Sea Studies. doi: 10.1080/14683857.2022.2121250
[46] Mustak, M., Salminen, J., Ple, L., & Wirtz, J. (2021). Artificial intelligence in marketing: Topic modeling, scientometric analysis, and research agenda. Journal of Business Research. doi:10.1016/j.jbusres.2020.10.044
[47] Noreen, U., Shafique, A., Ahmed, Z., Ashfaq, M. (2023). Banking 4.0: Artificial Intelligence (AI) in Banking Industry & Consumer's Perspective. Sustainability 2023, 15, 3682. https://doi.org/10.3390/su15043682
[48] Plastino, E., & Purdy, M. (2018). Game changing value from Artificial Intelligence: eight strategies. Strategy & Leadership, 46(1), 16–22. doi:10.1108/sl-11-2017-0106
[49] Rai, A., Constantinides, P., & Sarker, S. (2019). Next Generation Digital Platforms: Toward Human-AI Hybrids. MIS Quarterly, 43(1), iii-ix. https://misq.org/misq/downloads/
[50] Robinson, S., Orsingher, C., Alkire, L., De Keyser, A., Giebelhausen, M., Papamichail, K. N., … Temerak, M. S. (2019). Frontline encounters of the AI kind: An evolved service encounter framework. Journal of Business Research. doi:10.1016/j.jbusres.2019.08.038
[51] Rubin, H.J. & Rubin, I.S. (1995). Qualitative Interviewing: The Art of Hearing Data. Sage Publications.
[52] Seric, M., Gil-Saura, I., Mollá-Descals, A. (2016). Can advanced technology affect customer-based brand equity in service firms? An empirical study in upscale hotels. Journal of Service Theory and Practice
[53] Sheth, J., Jain, V., Roy, G. & Chakraborty, A. (2022). AI-driven banking services: the next frontier for a personalised experience in the emerging market. International Journal of Bank Marketing. 40. 10.1108/IJBM-09-2021-0449.
[54] Singh, S. (2022, Oct 07). How AI Is the Next Step In the Digitization Of the Finance Sector. https://www.entrepreneur.com/en-in/technology/how-ai-is-the-next-step-in-the-digitization-of-the-finance/436784
[55] The Economist. (2020). The Road Ahead: Artificial intelligence and the future of financial services. Retrieved from https://events.economist.com/events-conferences/americas/the-road-ahead-artificial-intelligence-and-the-future-of-financial-services
[56] Towers-Clark, C. (2019, Jan 15). 80% Of People Don't Trust AI With Money - How Can We Fix Its Image?. https://www.forbes.com/sites/charlestowersclark/2019/01/15/80-of-people-dont-trust-ai-with-money-how-can-we-fix-its-image/?sh=2dc1101f759a

[57] Trivedi, J. (2019). Examining the customer experience of using banking chatbots and its impact on brand love: The moderating role of perceived risk. Journal of Internet Commerce 18 (1): 91–111.
[58] UNFPA BiH, proMENTE, & Ipsos. (2021). Survey on youth emigration in Bosnia and Herzegovina. Retrieved from https://eeca.unfpa.org/en/publications/survey-youth-emigration-bosnia-and-herzegovina-0
[59] Vanderford, R. (2022, Mar 22). AI Experts Warn of Potential Cyberwar Facing Banking Sector. https://www.wsj.com/articles/ai-experts-warn-of-potential-cyberwar-facing-banking-sector-11647941402
[60] Violino, B. (2022, Sep 13). Artificial intelligence is playing a bigger role in cybersecurity, but the bad guys may benefit the most. https://www.cnbc.com/2022/09/13/ai-has-bigger-role-in-cybersecurity-but-hackers-may-benefit-the-most.html
[61] West, A., J. Clifford, and D. Atkinson. (2018). "Alexa, build me a brand" An Investigation into the impact of Artificial Intelligence on Branding. The Business & Management Review 9 (3): 321–330.
[62] Wirtz, J., Patterson, P. G., Kunz, W. H., Gruber, T., Lu, V. N., Paluch, S., & Martins, A. (2018). Brave new world: service robots in the frontline. Journal of Service Management. doi:10.1108/josm-04-2018-0119
[63] Xu, Y., Shieh, C.-H., Van Esch, P., & Ling, I-L. (2020). AI customer service: Task complexity, problem-solving ability, and usage intention. Australasian Marketing Journal. https://doi.org/10.1016/j.ausmj.2020.03.005
[64] Yanushefski, K. (2023, Mar 07). Measuring digital banking efforts with product analytics. https://www.pendo.io/pendo-blog/measuring-digital-banking-efforts-with-product-analytics/

Preliminary communication / Prethodno priopćenje

MARKETING U FUNKCIJI PRIVLAČENJA KUPACA U PRODAVAONICU

MIRJANA NEDOVIĆ
Veleučilište „Lavoslav Ružička“ u Vukovaru
Županijska 50, 32000 Vukovar, Hrvatska
mnedović@vevu.hr

ANA NOL
Veleučilište „Lavoslav Ružička“ u Vukovaru
Županijska 50, 32000 Vukovar, Hrvatska
an120030@vevu.hr

IVONA PERAK
Veleučilište „Lavoslav Ružička“ u Vukovaru
Županijska 50, 32000 Vukovar, Hrvatska
ip120034@vevu.hr

SAŽETAK

Na turbulentnom tržištu postoji veliki izbor i proizvoda i informacija tako da potrošači mogu lako pronaći ono što žele, zatim vrlo lako mogu usporediti ponude i cijene kod svih dostupnih trgovaca u vrlo kratkom vremenu. Stoga poduzeća pokušavaju neprestano učiti o potrošačima i njihovim potrebama, ulagati u prodavaonice i prodavače, proučavati konkurenciju i učiti od najboljih kako bi osvojili i zadržali svakog kupca. Korporativna i organizacijska struktura može imati utjecaj na konkurentnost prodavaonice, jer se uz pomoć iste može postići diferencijacija. Kroz elemente marketinškog miksa i kroz suradnju trgovine i proizvodnje, odnosno kroz vertikalni marketing postižu se bolji učinci u poslovanju.

Cilj ovog istraživanja je bio utvrditi koji elementi marketinga potrošače najviše privlače u prodavaonicu i na temelju čega donose tu odluku. Istraživanje je provedeno putem anketnog upitnika, Google obrasca, koji se sastojao od 8 pitanja. U radu se koristi istraživačka metoda deskripcije i analize i implikacija obrađenih pojmova na atraktivnost prodavaonice, potom se utvrđuju stavovi ispitanika prema određenim marketinškim aktivnostima.

KLJUČNE RIJEČI: Marketing miks, privlačenje kupaca u prodavaonicu, korporativna i organizacijska kultura

1. UVOD

Maloprodaja prolazi kroz značajnu strukturnu transformaciju (Egan, Burt, Hulman, Johansson, Beckam, & Michael, 2021), i primjećuje se da prodavaonice uvelike ulažu u inovacije prostora, te je pretpostavka da se želi unaprijediti ugodnost kupnje, što za posljedicu može biti veći broj

novih potrošača, ali i zadržavanje postojećih. Danas se vrlo lako može doći do bilo koje informacije o proizvodu, trgovini, trenutnim akcijama koje provodi trgovina, a pogođena kombinacija marketinških aktivnosti značajno utječe na posjećenost trgovine. Stoga je izbor marketinških aktivnosti važan element koji privlači potrošače, no ništa manje ne izostaje niti dobro određena korporativna i organizacijska kultura. Potrošači odlučuju sami na koji način će uložiti svoje vrijeme i gdje će potrošiti svoj novac, a na turbulentnom tržištu prisutne su mnogobrojne trgovine koje međusobno konkuriraju i bore se konkurentsku prednost.

2. KORPORATIVNA I ORGANIZACIJSKA KULTURA U FUNKCIJI PRIVLAČENJA POTROŠAČA

Organizacijska kultura predstavlja šire obrasce ponašanja, zajednička uvjerenja i vrijednosti koje dijele pripadnici organizacije. Njezina se narav može zaključiti iz onoga što ljudi govore, čine i misle unutar okvira organizacijskog ambijenta. Uključuje procese učenja i prenošenja znanja, uvjerenja i modela ponašanja tijekom određenog vremenskog razdoblja, što ukazuje na to da organizacijska kultura obično ostaje relativno stabilna te se ne mijenja brzo (Gutić & Barbir, 2009.).

Korporativna i organizacijska kultura predstavlja skupinu karakteristika po kojima se pojedino poduzeće prepoznaje na tržištu, pokazuje karakter samog poduzeća te je osmišljen kako bi ispunili svoje poslovne ciljeve. Očituje se prateći određene vidljive i nevidljive simbole. Vidljivi simboli su slogani, priče, oblačenje i sve ono što određuje atraktivnost organizacije i njezinih članova. Nevidljivi simboli i znakovi jesu stavovi, vrijednosti, uvjerenja i mišljenja članova organizacije. Korporativna kultura značajno djeluje na poslovnu i tržišnu uspješnost poduzeća.

Uz pomoć dobro definirane korporativne kulture može se stvoriti dobra percepcija u javnosti, jer će se zaposlenici ponašati na ujednačen način. Takav način ponašanja biti će prepoznat u javnosti. Na prodajnom mjestu izrazito je bitan odnos prodajnog osoblja prema potrošačima, njihova obučenost, izgled, ponašanje kao i spremnost na suradnju. U tom smislu za potrošača prodavaonica može biti manje atraktivna ako osoblje nije spremno za suradnju ili su nedovoljno obučeni za pružanje kvalitetnih informacija o nekom proizvodu, i suprotno od navedenog. Svaki akter koji se nalazi na tržištu nastoji o sebi stvoriti dobru i pozitivnu sliku, žele steći određenu reputaciju i imidž. Kako bi se postigao pozitivna percepcija, osim dobro osmišljenog i dizajniranog vanjskog i unutarnjeg izgleda potrebno je potrošačima osigurati dobru emociju prilikom boravka u prodavaonici. Dobra korporativna i organizacijska kultura uvelike će doprinijeti u ostvarenju takvim nastojanjima.

3. ČIMBENICI MARKETINGA U PRIVLAČENJU KUPACA U PRODAVAONICU

Marketing mix (4P) je jedan je od marketinških modela koji se može koristiti za poboljšanje kreiranja marketinške strategije. Tako marketinški mix može pomoći tijekom procesa planiranja, može poslužiti kod uspostavljanje ciljeva kao i analiziranja poslovanje s konkurencijom. Marketing mix obuhvaća proizvod, promociju, cijenu i mjesto. 4“P“ se smatra menadžerskim alatom uz pomoć kojeg se zadovoljavaju potrošači (Mcarthy, 1964). Mnogi autori kasnije, u literaturi nadodaju i ostale element na „4P“. Uz pomoć elemenata marketing

miksa izrađuje se najprikladniji marketinški koncept s kojim će se nastupiti na tržištu. U nastavku će se elementi marketing miksa detaljnije objasniti.

Proizvod i promocija - općenito, ljudi iz područja marketinga, ali i oni koji to nisu, uglavnom gledaju na proizvode kroz njihova funkcionalna svojstva kao što su kvaliteta, dizajn, marka i slično (Gutić & Barbir, 2009). Na privlačenje potrošača i njihovo ponašanje proizvod i usluge imaju odlučujući utjecaj na njihov izbor prilikom kupovine, tako na to utječe niz elemenata neki od njih su pakiranje, cijena, kvaliteta, dizajn, marka.
Promotivni elementi uključuju oglašavanje, odnose s javnošću, izravnu prodaju i prodajne promocije (Gordon, 2012).

Cijena i mjesto - Prodajna cijena proizvoda predstavlja iznos koji su potrošači spremni platit za određeni proizvod ili uslugu. Prilikom određivanja cijena na temelju troškova u obzir se trebaju uzeti i troškovi vezani uz istraživanje i razvoj, proizvodnju, marketing i distribuciju Određivanje cijena koje se prvenstveno temelji na kvaliteti ili vrijednosti koju potrošači percipiraju poznato je kao određivanje cijena temeljeno na vrijednosti.

Kada se određuje mjesto distribucije bitno je uzeti u obzir vrstu proizvoda koji se prodaje. Osnovni potrošački proizvodi, kao što su prehrambeni proizvodi često se mogu pronaći u svim trgovinama, dok premium potrošački proizvodi obično su dostupni u odabranim prodavaonicama (Kenton, 2023). Nadalje, privatne marke se mogu naći u točno određenoj prodavaonici, te kupci tada ciljano idu u prodavaonicu.

Unaprjeđenje prodaje - uz promociju ide i unaprjeđenje prodaje, kojom se privlače kupci u prodavaonicu pa tako prodavaonica i određeno poduzeće za svoje potrošače mogu pripremiti razne kupone, promotivna pakiranja, nagradne igre za potrošače, prezentacija proizvoda, degustacije, besplatni probni uzorci.

Kupci predstavljaju ključnu imovinu svakog poduzeća i predstavljaju najvažniju interesnu skupinu u lancu vrijednosti. Prodajno osoblje i poslovni partneri moraju biti obučeni u prikupljanju, organizaciji i upotrebi informacija o klijentima kako bi se osiguralo uspješno poslovanje (Calvin, 2009).

Odabir najbolje marketinške strategije zahtijeva dobro razumijevanje poslovnog okruženja, marketinške postavke, teorijske i praktične domene marketinga, potrebe i ponašanja kupaca i poznavanje konkurencije, njezine pozicije i strategije svih konkurenata na tržištu. Jedan od alata koji se koristi za upravljanje i učinkovitost marketinških strategija je marketinški miks (Azad, Maddahi, & Jouzdani, 2021).

Prodavaonica može povećati svoju atraktivnost za potrošača uvođenjem aktivnosti kao što su**:** dijeljenje kupona, zatim provođenje demonstracije proizvoda, dijeljenje besplatnih uzoraka, sakupljanje trgovačkih markica i prisutnost izložaka na mjestu prodaje (Gutić & Barbir ,2009). Važnost identifikacije onih dominantnih od postojećih brojnih atributa, naglasili su i različiti autori (Karmakar & Knutson, 2015); (Sohail & Rabbie, 2012); (Sadi & Saricimen).

4. IZBOR PRODAVAONICE

Kupci troše značajan dio vremena i truda u odabiru određene trgovine za njihovu kupnju. Izbor određene trgovine između brojnih konkurentskih trgovina je pod utjecajem različitih karakteristika same trgovine (Dennis, 2005).

Novonastale trgovine mogu privući kupce zbog dobrog ambijenta, međutim ponekad kupnje mogu biti i niže od očekivanih, pa samim time i niža profitabilnost trgovaca na malo (Piyush Sinha & Banerjee, 2004). Kupac prije svega predviđa da u prodavaonici neće samo dobiti kupljeni proizvod već niz različitih usluga. Tako samim time ako u prodavaonici postoje usluge kao što su besplatno parkiranje, restorani, popravci, caffe bar, izgledno je da će se privlačiti više kupaca. Dodatni sadržaji postali su sastavni dio cjelokupne ponude za kupca.

Na izbor prodavaonice svakako će utjecati njezina lokacija, zato mnogi trgovački centri pomno biraju mjesto izgradnje vodeći računa o gustoći naseljenosti, blizini što većem broju potrošača, uvažavajući i značaj prilaznih cesta, dostupnog parkinga, pristupa za pješake i sl. Nadalje asortiman je ograničen kvadraturom prodavaonice, no važan je čimbenik i kontinuitet u dostupnosti proizvoda i usklađenosti proizvoda koji se nude sa potrebama ciljne skupine i okruženja u kojem je trgovina locirana.

Na osnovu vanjskog izgleda prodavaonice stvara se prvi dojam u glavi potrošača o samom prodajnom mjestu, pa je značaj ovog elementa od izuzetne važnosti za privlačenje kupaca. Čak i ako ne postoji namjera kupovine, kreativan i lijep izlog zagolicat će znatiželju potrošača, te će ga privući u prodajni prostor. Ukoliko je i unutarnji prostor tj. interijer prodavaonice s posebnom pažnjom osmišljen, potrošač će osjećati ugodnost ambijenta, osjećat će se dobro i vrlo vjerojatno će i posegnuti za proizvodom.

Prema Ballantine & Parson (2010) kada potrošač uđe u trgovinu, glazbu ne percipira izolirano; ne osjete miris, a da ne vide i boje. Stoga, dobra kombinacija boja, ugodan ambijent i dobar raspored robe u prodavaonici bit će presudna kombinacija za postizanje željenog učinka.

Prilikom biranja prodavaonice, nužno je istaknuti da je komunikacijska politika pod snažnim utjecajem digitalizacije. Za razliku od tradicionalnih marketinga, suvremena internetska komunikacija omogućuje komunikaciju potrošača odmah, i to s prodavaonicom, te je moguće podijeliti povratne informacije kao i mišljenja o proizvodu ili marki i biti izravno uključeni u razvoj marketinških strategija (Cham, Cheah, Memon, Fam, & Laszlo, 2022). Mišljena potrošača o prodavaonici, usluzi, iskustvu kupovine i sl., koja se objavljuju javno na društvenim mrežama, imaju snažan utjecaj na odabir prodavaonice.

5. EMPIRIJSKO ISTRAŽIVANJE O ELEMENATIMA MARKETINGA I IZGLEDU PRODAJNOG MJESTA U FUNKCIJI PRIVLAČENJA POTROŠAČA U PRODAVAONCU

5.1. METODOLOGIJA ISTRAŽIVANJA

Za potrebe rada je provedeno istraživanje putem anketnog upitnika. Anketa je provedena s punoljetnim osobama, a u istraživanju je ispitano 60 ispitanika te se anketa sastojala od 8 pitanja. Istraživanje je provedeno od 01.-20.04.2023. godine. Cilj ovog istraživanja je bio utvrditi koji elementi marketinga potrošače najviše privlače u prodavaonicu, koliko izgled prodajnog mjesta utječe na kupnju i na temelju čega donose tu odluku. Istraživanje se provodilo putem anketiranja u obliku online ankete koja je izrađena putem Google obrasca. Rezultati istraživanja su analizirani deskriptivnom statistikom i prikazani pomoću grafičkih prikaza.

5.2. REZULTATI ISTRAŽIVANJA

Grafikon 1. Rodna struktura ispitanika

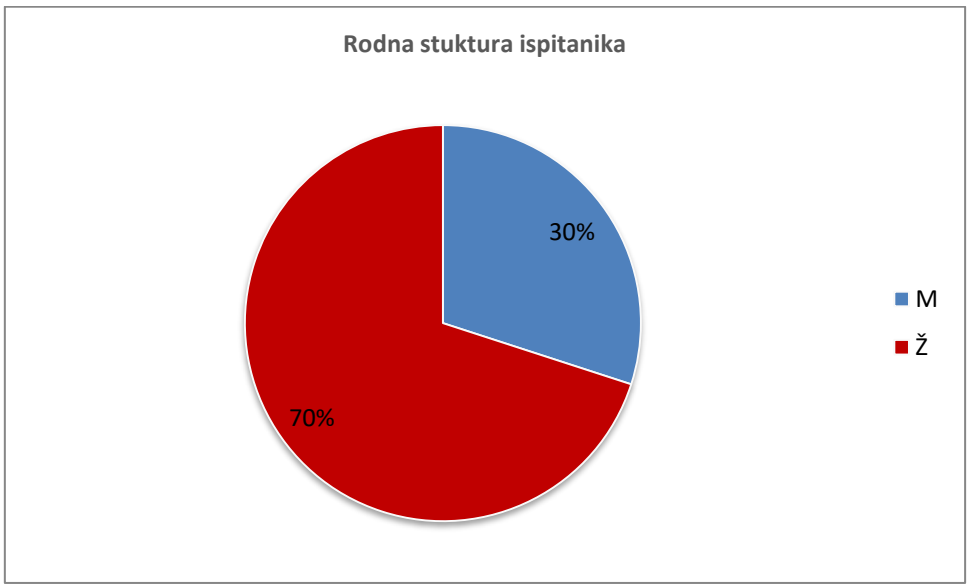

Izvor: Izrada autora

Prvim pitanjem željela se utvrditi rodna struktura ispitanika. Prema grafikonu br.1. može se vidjeti da je većina ispitanika ženskog spola i to 70%, dok je 30 % ispitanika muškoga spola.

Grafikon 2. Dob ispitanika

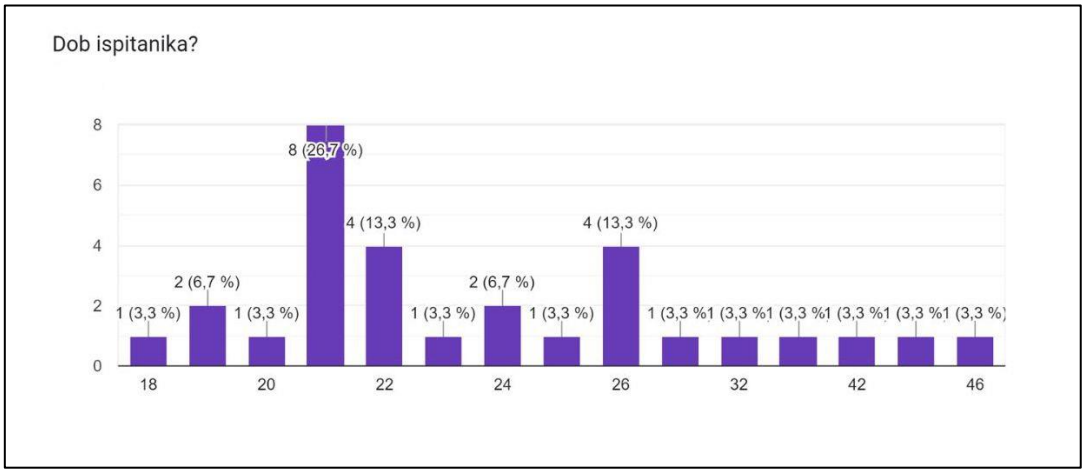

Izvor: Izrada autora

Iz grafikona br.2. Dob ispitanika, vidljivo je da su ispitanici u rasponu životne dobi od 18 do 46 godina. U najvećem postotku je ispitanika u dobi od 21 godinu odnosno njih 26,7 %, zatim u dobi od 22 i 26 godina njih 13,3% , zatim od 19 i 24 godina, njih 6,7%.

Grafikon 3. Što potrošače najviše privlači u prodavaonicu

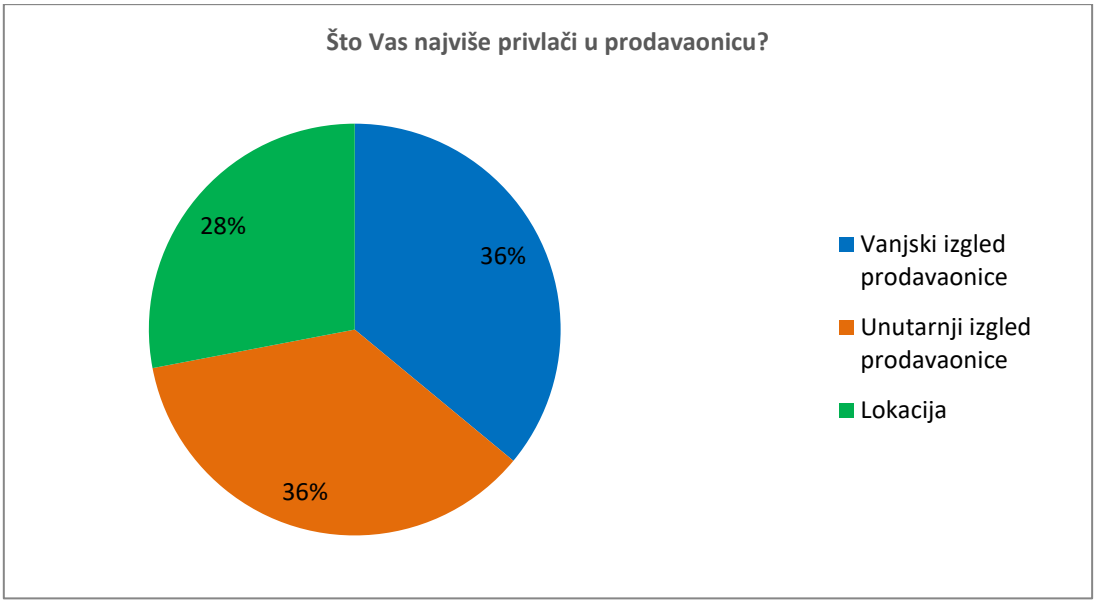

Izvor: Izrada autora

Iz grafikona br. 3. vidljivo je da se 36% ispitanika izjasnilo kako im je najvažniji vanjski izgled prodavaonice, te je isti broj ispitanika izjavilo da im je najvažniji unutarnji izgled prodavaonice, njih 36%, dok se 28% ispitanika izjasnilo da im je najvažnija lokacija prodavaonice.

Grafikon 4. Značaj izgleda prodavaonice prilikom kupnje

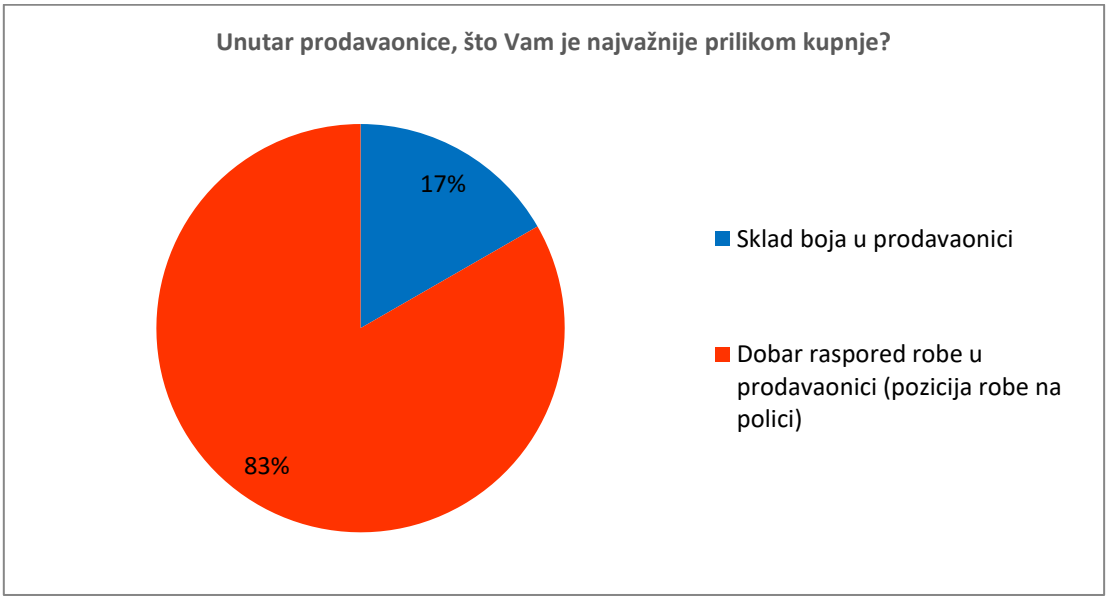

Izvor: Izrada autora

Iz grafikona 4. vidljivo je da je najveći broj ispitanika izjavilo da im je važniji dobar raspored robe u prodavaonici (pozicija proizvoda), njih 83%, a njih 17% je izjavilo da im je prilikom kupnje najvažnija kreativnost prodavaonice, odnosno boja i sklad u prodavaonici.

Grafikon 5. Marketinške aktivnosti

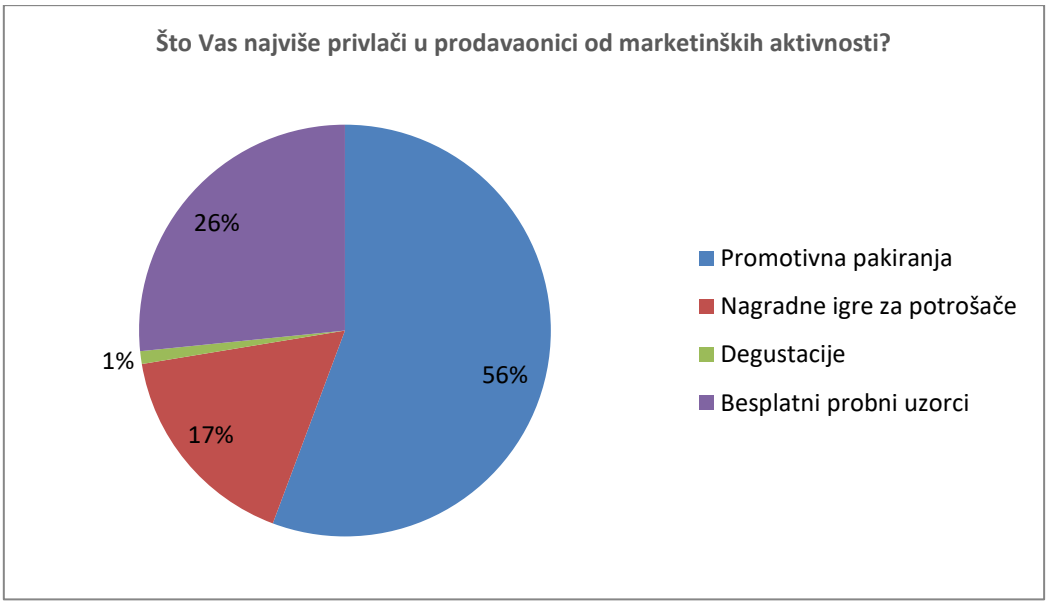

Izvor: Izrada autora

Grafikon 5. prikazuje što potrošače najviše privlači u prodavaonici prema marketinškoj aktivnosti. Vidljivo je da 56% ispitanika smatra da su to promotivna pakiranja, njih 26% smatra da su to besplatni uzorci, njih 17% smatra da su to nagradne igre za potrošače, a 1% smatra da su to degustacije.

Grafikon 6. Utjecaj promotivnih aktivnosti

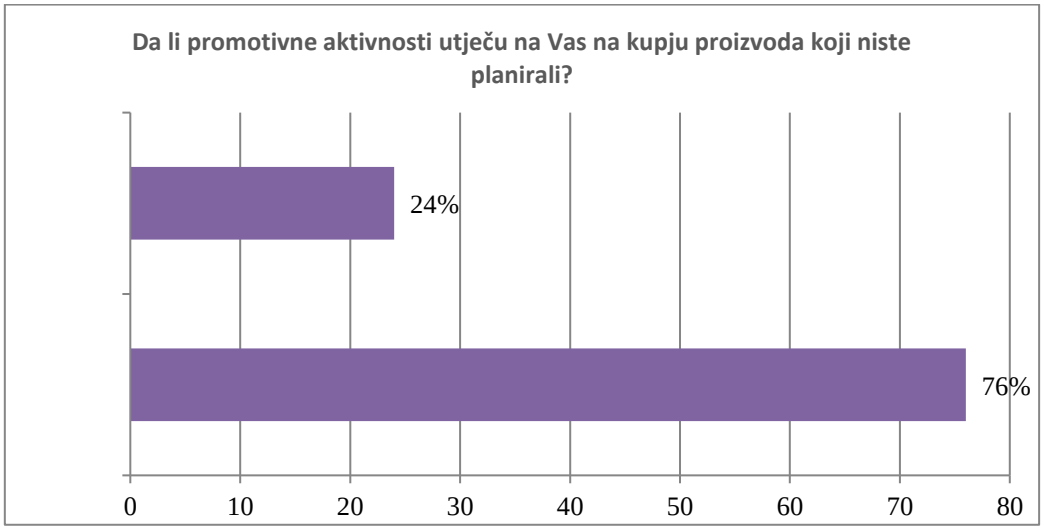

Izvor: Izrada autora

Grafikon 6. prikazuje utječu li promotivne aktivnosti na neplaniranu kupnju. Iz grafikona je vidljivo da 76% ispitanika smatra kako promotivne aktivnosti utječu na njih tako da kupnju proizvode koje prvobitno nisu planirali kupiti, dok njih 24% smatra kako promotivne aktivnosti ne utječu na njih da kupuju ne planirane proizvode.

Grafion 7. Ambijent prodavaonice

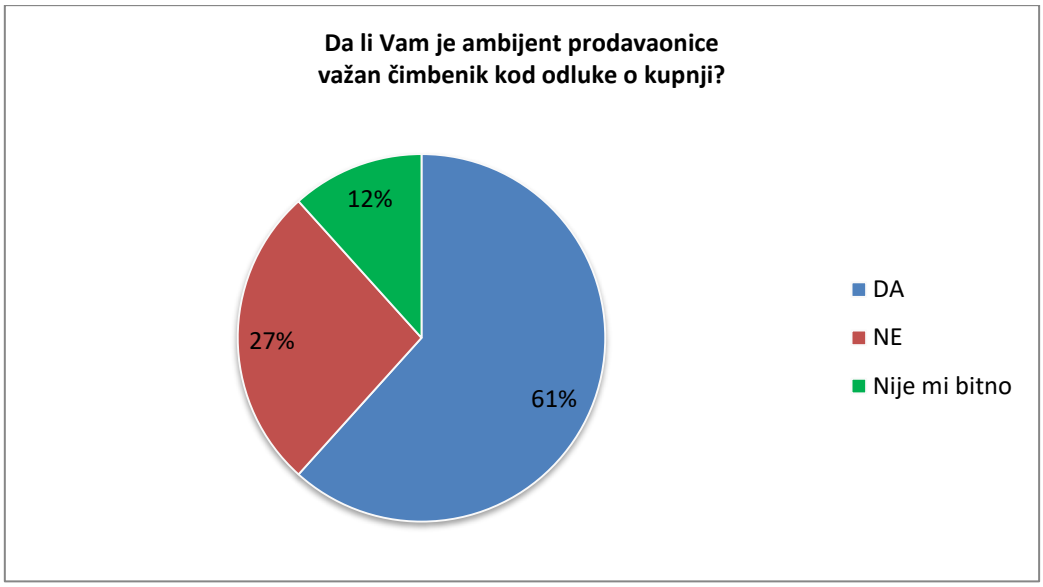

Izvor: Izrada autora

Grafikon 7. prikazuje važnost ambijenta prodavaonice kao važnog čimbenika kod odluke o kupnji. 61% ispitanika se izjasnilo kako im je ambijent prodavaonice važan čimbenik kod odluke o kupnji, dok njih 27% odnosno izjavljuje kako im nije važan, a 12% ispitanika su de izjasnili da im ambijent nije bitan čimbenik kod kupnje.

Grafikon 8. Utjecaj neljubaznosti prodajnog osoblja na kupcu

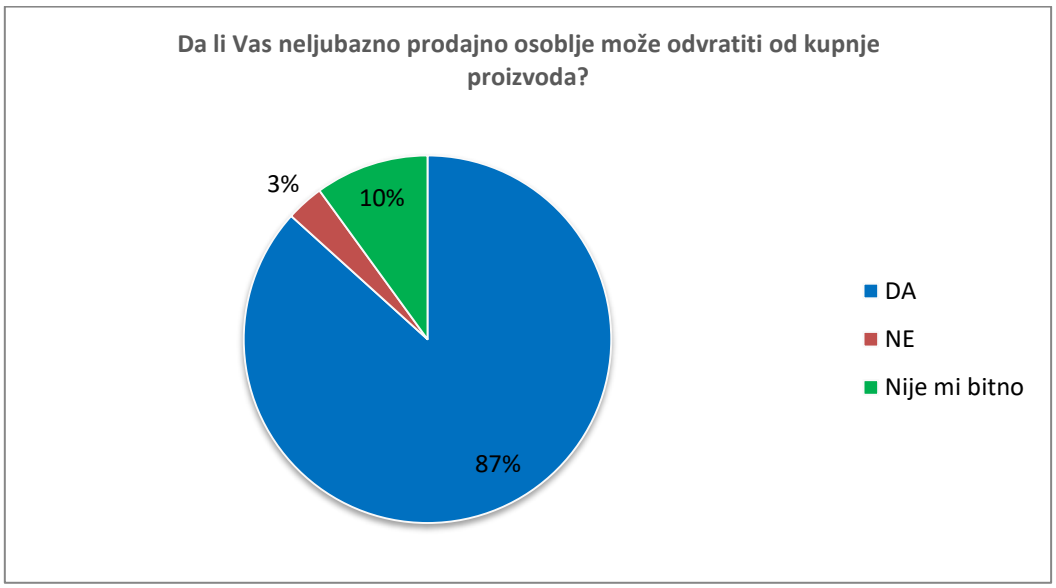

Izvor: Izrada autora

Grafikon 8. prikazuje važnost ljubaznosti prodajnog osoblja. Prema istraživanju njih 87% se izjasnilo kako ih neljubaznost prodajnog osoblja može odvratit od kupnje proizvoda, 10% ispitanika se izjasnilo kako im to nije bitno, a 3% ispitanika izjavljuje da ih neljubaznost prodajnog osoblja ne može odvratit od kupnje.

6. ZAKLJUČAK I BUDUĆA ISTRAŽIVANJA

Opstanak na tržištu jedan je od najvažnijih aspekata današnjeg poslovanja, kao i biti profitabilan, privući i zadržati što više potrošača kao i ostvariti konkurentsku prednost. Privlačenje potrošača dio je koji dobiva najviše pažnje. Danas ga prodavači koriste na razne načine, a jedan od najreprezentativnijih načina jest oglašavanje, putem različitih medija, plakata, letaka, društvenih mreža, trgovačkim marketingom i sl. Temeljem provedenog istraživanja uočava se važnost marketinških aktivnosti u smislu onih koji u najvećoj mjeri privlače potrošače u prodavaonicu. Potrošače u prodavaonici privlači niz čimbenika koji utječu na njihovu odluku o kupnji. Temeljem istraživanja može se izdvojiti nekoliko ključnih faktora: Vizualni identitet, uređenje (unutarnje i vanjsko), zatim lokacija. U najvećem broju su podložni utjecajem marketinških aktivnosti. Privlačan i dobro organiziran izgled prodavaonice, privlačna rasvjeta, estetski uređen izlog i police privlače potrošače te stvaraju pozitivan prvi dojam. Sklad boja i pozicija robe na polici daju niz mogućnosti za poboljšanje. Specijalne ponude, popusti, degustacije, nagrade, uzorci i sl. također su neizostavne promotivne aktivnosti koje privlače veći broj potrošača. Ambijent prodavaonice, ugodna atmosfera, pozitivna energija i opuštena okolina čine kupovinu ugodnom i potiču povratak u prodavaonicu. Uloga prodajnog osoblja je od izrazite važnosti, jer neobučeno i neljubazno prodajno osoblje može negativno utjecati na dolazak u prodavaonicu. Različiti potrošači mogu imati različite prioritete i preferencije, pa uspješne prodavaonice često kombiniraju više ovih faktora kako bi privukle širok spektar potrošača. Također i korporativna i organizacijska struktura imati će utjecaj na ponašanje svih zaposlenih propisanim normama i standardima ponašanja. Nove zahtjeve i kritike kupca s posebnom pažnjom je potrebno uvažavati i prihvatiti kako bi se spriječio odlazak kod konkurencije. Rezultati istraživanja će biti korisni menadžerima koji upravljaju prodavaonicama, jer se istraživanjem može spoznati najatraktivnije aktivnosti koje potiču potrošače na ulazak u prodavaonicu. Menadžeri se također mogu lakše usredotočiti na sve svoje resurse s kojima raspolažu, kako bi stvorili pozitivno okruženje, dobar ambijent za potrošača.

REFERENCE

[1] Azad, I., Maddahi, I., & Jouzdani, J. (3 2021). A game of theory approach to selecting marketing mix strategies. *Journal of Advances in Manageent Research*, str. 139-158.

[2] Ballantine, W., & Parson, G. (2010). Atmospheric cues and their effect on the hedonic retail experience. *International Journal of retail and Distribution Management*, str. 641-653.

[3] Cham, H., Cheah, H., Memon, A., Fam, S., & Laszlo, J. (2022). Digitalization and its impact on conteporary marketing strategies and practices. *Jurnal of Marketing Analytics*, str. 103-105.

[4] Dennis, C. (2005). *Objects of Desire:Consumer behavior in Shopping Centre Choices.* New York: Šalgrave Macmillan.

[5] Egan, W., Burt, S., Hulman, J., Johansson, U., Beckam, A., & Michael, C. (2021). Ease or excitiment?exploring how concept stores contribute to retail portfolio. *International Jounal of Retail&Disribution Management*, str. 1025-1044.

[6] Gordon, R. (2012). "Re-thinking and re-tooling the social marketing mix". *Australasian Marketing Journal, Elsevier*, str. 122-126.

[7] Gutić, D., & Barbir, V. (2009.). *Ponašanje potrošača.* Makarska: Fortunagraf d.o.o.

[8] Karmakar, S., & Knutson, B. (2015). Cost conscious? The neutral and behavioral impact of rice primacy on decision-making. *Journal of Marketing Research, 4*, str. 467-481.

[9] Kenton, W. (27. 3 2023). *Investopedia*. Preuzeto 30.3.2023.. 3. 2023. iz Marketing Mix: The 4 Ps of Marketing and How to Use Them: https://www.investopedia.com/terms/m/marketing-mix.asp
[10] Mcarthy, J. (1964). *Basic Marketing: A Managerial approach, rev.ed.* Irwin.
[11] Piyush Sinha, K., & Banerjee, A. (2004). Store choice in an evolving market. *International Journal of Retailing&Distribution Management*, str. 482-494.
[12] Sadi, A., & Saricimen, T. (n.d.). Value factors determining consumer satisfaction at full-scale restaurants in Saudi arabia. *Journal for Global Business Advancement, 4*, str. 285-294.
[13] Sohail, A., & Rabbie, H. (2012). Drivers of customer satisfaction: Perspectives from the food retail sector of an Arab nation. *Journal for Global Business Advancment, 3*, str. 181-192.

Preliminary communication / Prethodno priopćenje

MAPPING THE CUSTOMER EXPERIENCE: UNVEILING THE CUSTOMER JOURNEY IN THE NAIL INDUSTRY

PhD **DAVOR ŠIROLA**, College Professor
Polytechnik of Rijeka
Vukovarska 48, 51000 Rijeka, Croatia
davor.sirola@veleri.hr

M.Sc. **ROBERT STRAHINJA**, Lecturer
Polytechnik of Rijeka
Vukovarska 48, 51000 Rijeka, Croatia
robert.strahinja@veleri.hr

MAJA ARBANAS, bacc. oec.
Polytechnik of Rijeka
Vukovarska 48, 51000 Rijeka, Croatia
marbanas@veleri.hr

ABSTRACT

After a period of a low-touch customer service approach due to the recent pandemic, delivering value to customers again becomes a focus for entrepreneurs in originally designed business models in the service industry. Pandemic experiences have prompted customers to accept the usual service process changes readily. A valuable tool for analyzing customer behavior through the most critical touchpoints of the value delivery process is customer journey mapping. In this research, the CJM tool was applied using the example of a micro-entrepreneur in the nail industry. Customer experiences (N = 476) indicate that users attach the most significant importance to appointment availability, loyalty/reward programs, staff expertise, and price. By creating a customer journey map for customers of the analyzed business entity and other surveyed service users of different providers, differences and potential improvement touchpoints in the entrepreneur's service process have been identified.

KEYWORDS: Customer Journey Mapping, Customer Experience, Nail Industry

1. INTRODUCTION

Historically, providers' interest in satisfying customers has gone through various stages. From the era of manual, artisanal production and direct, almost familial connections with customers, through the period of mass production and focus on product quality, to modern times and the global growth of the service sector's share, where delivering greater value to customers is once again placed at the forefront (Reis et al., 2003: 195-196). Empowering customers through the increasing use of online options for price and offer comparison, personalized content, and greater trust in online reviews has put many smaller or local providers in a position where they

must offer their products or services, aware that customers will compare them with the offerings and experiences they enjoy with market leaders like Amazon, Google, or Apple (Duncan et al., 2016, 2016: 3). Furthermore, the recent COVID-19 pandemic, with its low-touch approach, has brought about a meteoric rise in online sales. For instance, between the end of March and mid-May 2020, global online sales increased by 29% (We Are Social, Hootsuite, July 2020: 163), and this growth trend persisted even after the pandemic. Weekly online sales (age 16-64) increased by 52.2% in the first quarter of 2023 compared to the first quarter of 2021 (We Are Social, Meltwater, 2023a: 300; We Are Social, Hootsuite, 2021: 167). Similar trends are observed in Croatia, where in 2022, compared to 2021, there was a 3.9% increase in the number of online customers, or a growth of 94,000 customers, totaling 2.51 million (We Are Social, Meltwater, 2023b: 59). These trends have accelerated the necessity of business digitalization and the easier accessibility of products and services in the online offering.

With the change in the structure of the purchasing process, the pandemic has temporarily or permanently altered consumption patterns and customer behavior. For example, in the nail care industry, which is the focus of this paper, customers have become more inclined towards healthier lifestyles and products. In 2020 and 2021, more innovative, safer, and non-toxic products were introduced (Barnes, 2021). The nail salon industry, chosen as the focus of this micro-level study, is a large market. For illustration, the global nail salon market size was valued at USD 11 billion in 2022 (https://www.grandviewresearch.com), whereas the global cinema box office market was valued at 25.34 billion in 2022 (https://www.pwc.com). A similar comparison for the Croatian market is not available.

Timely recognition of changes in customer behavior can be facilitated by tools such as customer journey mapping (CJM), the role of which in enhancing customer experience during the decision-making process, is analyzed in the following sections of this paper. Furthermore, a customer journey map is elaborated upon using the example of a micro-level business entity in the nail care industry.

2. LITERATURE OVERVIEW

The concept of the customer journey is closely related to the notion of customer experience. For instance, Følstad & Kvale (2018: 15) found this link in 40 (out of 45) papers in their systematic literature review. It is also evident from the comprehensive definition of customer experience as a multidimensional construct based on cognitive, emotional, behavioral, sensory, and social reactions to a company's offerings throughout the entire customer purchasing journey (Waqas et al., 2021: 151).

The pioneers of studying consumer experience as a distinct research area are considered to be Pine and Gilmore (1998), who classified experience as a critical element of consumer offerings akin to goods, products, and services, as well as Schmitt (1999), who established a distinction between traditional and experiential marketing and introduced five strategic experiential modules—sense, feel, think, act, and relate experience (Waqas et al., 2021: 144).

The origin of the CJM concept is somewhat unclear and is associated with Jan Carlzon's concept of moments of truth (1987). However, the actual phenomenon of CJM is attributed to authors Carbone and Haeckel, who spoke about the experience blueprint in their seminal work (1994, cited in Kalbach, 2021: 287). The beginnings of applying customer journey for mapping

customer experience are tied to authors Theng et al. (1999, cited in Pantouvakis & Gerou, 2022: 7), who aimed to enhance service processes by mapping customer experience.

Mapping is a tool frequently used in service design methodology, and the user-centered approach involves observing actual user behavior and involving them in improving and creating services (Marquez et al., 2015: 136).[1] In addition to CJM, these tools encompass various others, such as service blueprints, experience maps, or mental model diagrams, which Kalbach (2021: 5) refers to as alignment diagrams, as they visualize the interaction between people and organizations.

CJM is defined from various standpoints. In their literature review of consumer journey and CJM, Pantouvakis & Gerou (2022: 9) found 146 scientific articles (between 1999 and 2019) and, through various approaches, distilled this definition: CJM is a depiction of the customer journey that visualizes the overall customer experience (CX) and includes all touchpoints between the customer and the company or service throughout the entire decision-making process and customer journey stages.

One key concept within CJM is touchpoints between customers and the company or service, through which the entire customer service process is analyzed. It is crucial to take a holistic approach to view the entire service - the entire journey, rather than just individual touchpoints, as excellent performance at individual touchpoints might result in a less satisfactory overall customer experience. Customer journey, in fact, significantly correlates with customer satisfaction or the propensity to recommend a service/product compared to touchpoints across various industries (Duncan et al., 2016: 5 and 20). However, CJMs are not just lists of touchpoints. They include a deeper understanding of customer motives and attitudes, decision-making processes, primary elements of customer satisfaction, and more (Kalbach, 2021: 299). Such an approach has been applied in this paper and is further explained in the following section.

3. METHODOLOGY

The CJM in this paper depicts the activities, thoughts/feelings, customer pains, objectives, situations (satisfaction with specific service elements), and touchpoints, following the approach suggested by Kalbach (2021: 189 and 300). It usually includes a (marketing) persona description, but due to volume, it is not the subject of this paper. A questionnaire was prepared to determine customer motives, attitudes, and behaviors that cover three major stages of the decision-making process or the customer journey, following the Lemon & Verhoef (2016: 77) approach: pre-purchase stage (recognition, search), purchase stage (choice, ordering, payment), and post-purchase stage (recommendation, loyalty). The questionnaire contains a total of 51 statements that explore the mentioned components of the customer journey, as well as the popularity of specific salons among respondents, the most commonly used types of services, preferred payment methods, and an additional four demographic variables (age, gender, status, and residence/domicile). All statements were independently developed. For most variables (except demographic ones), an interval (Likert) scale with five levels was used. Reliability testing determined that variables tested with the Likert scale have an acceptable Cronbach's α value of 0.847. The questionnaire for online completion was prepared using the Google Forms

[1] Although the authors Marquez et al. (2015) use the term "user" instead of "customer," the concepts of customer experience (CX) and user experience (UX) should not be equated. A more detailed differentiation of the terms can be found, for example, in Lee et al., 2018; 14.

tool. Since no pilot testing of the finalized questionnaire was conducted, this is indicative research.

The analysis was conducted in the field of nail care and on the example of a micro-entity - a nail care salon as a case study. The questionnaire was distributed to the email addresses of around 150 users of the nail care salon as a case study, as well as to the addresses of students, former students, and staff of the Polytechnic of Rijeka. A total of 476 complete responses were collected during June 2023. The sample characteristics are provided in Table 1.

Table 1. Demographic Characteristics of the Sample - Excerpt

Characteristics	**N**	**%**	**Characteristics**	**N**	**%**
Gender	**476**		*Age (years)*	**476**	
Female	465	97,7	< 18	4	0,8
Male	11	2,3	18 - 24	48	10,1
Residence/Domicile	**476**	%	25 - 34	222	46,6
I live in the City Center	62	13,0	35 - 44	148	31,1
I live outside the City Center of Rijeka	212	44,5	45 - 54	33	6,9
I live in Primorje-Gorski Kotar County	58	12,2	55 or more	21	4,4
I live outside Primorje-Gorski Kotar County	144	30,3			

Source: research

For a global comparison of this sample characteristics, the women segment dominated the market by around 69% in 2022 (https://www.grandviewresearch.com). In the sample of this research, the proportion of women might be unrealistically high. On the contrary, the age structure is approximately similar. The age group of 19 – 40 years dominates the global nail salon market with 46% in 2022 (https://www.grandviewresearch.com), while in this sample, the age group of 18 – 34 years constitutes 51.9%

4. RESULTS

The statistical tool Jamovi 2.3.21 was used to analyze the collected empirical data. Non-users of nail salons were initially excluded from the analysis, leaving a sample of 297 respondents who identified themselves as current or former users of nail salons. ANOVA and independent sample tests were conducted to compare the results of nail salon users concerning demographic and other control variables. Statistically significant differences were found in certain variables concerning the age of respondents and the frequency of visits. However, within the context of this study, the focus was placed on differences established between 'own' users (of a studied nail care salon) and other users (31 out of 55 variables). For this reason, the CJM is presented separately (Tables 2 and 3 below) for 'own' users (N = 92) and 'other' users (N = 205).

Table 2. Customer Journey Map for 'Own' Users

Stage	**PRE-PURCHASE**									
	Awareness of the salon brand		Selection criteria for choosing a salon	Regularly seeking nail design ideas before visiting the salon	Method of scheduling appointments		Experience with online appointment booking	Potential improvements in the booking process	
Activities	**Salon selection**				**Appointment scheduling**				
Thoughts / Feelings	Stimulating curiosity; Reducing insecurity			Entrusting to expertise; Approval	Time and care savings				
User Pains	Brand confusion; Risk of wrong choice			Reluctance to risk trying some new	Younger clients lack sufficient online options			Concerns about appoint. arrangement	
Objectives	Promotion through influencers and social media		Reevaluate working hours (more time slots)	Attract more younger clients	Promote online booking channels			Digitalization; Working hours?	
Situation	Word-of-mouth recommendation	76,1%	1. Service quality and staff expertise	40% fully agree or agree (43.3% among those aged 18-34), Average rating 3.11 (on a scale of 1-5)	SMS / WhatsApp / Viber	47,8%	38% have this experience (average rating 3.69 on a scale of 1-4)	Multiple appointments	3,60
	Regular client of the hair department	12,0%	2. Cleanliness and salon hygiene		Phone	33,7%		Introduction of the reminder system	3,54
	Following a favorite manicurist	7,6%	3. Appointment availability		Other	14,1%		Introduction of online reservations	3,39
	Through social media	2,2%	4. Quick and easy appointment reservation		Through social media	2,2%		Salon working hours	2,97
	Through internet searches	1,1%	5. Price and affordability		Through online system	2,2%		Faster response to reservations	2,96
	Proximity to the location	1,1%						(Scale 1 - 5)	
	Gift voucher	0,0%							
Touch-points	Social media/ Influencers		Working Hours	Appointment availability	Quality	Posting new nail designs on social media		Web applications	Social media	Appointment availability	Reminder application

Source: research

Table 2. Customer Journey Map for 'Own' Users – Continued

Stage	PURCHASE				POST-PURCHASE					
	Experience during the visit	Possible improvements during the visit		Satisfaction with the overall service	Possible improvements after the service is provided		Acceptable price/quality ratio	Willingness to pay for premium services		
Activities	**Nail styling process**				**Usage**					
Thoughts / Feelings	Trust in the quality and expertise of the staff				Are clients satisfied; will they return; recommend the salon to others					
User Pains	:)	Location with more accessible parking?			Regular clients want to be rewarded					
Objectives	Maintain good client experiences				Building loyalty		Consider pricing levels	Offer premium services		
Situation	Rated 3,76 (on a scale of 1-4)	Parking	3,40	Rated 4,78 (on a scale of 1-5)	Loyalty program/rewards for loyalty	3,84	Rated 4,65 (on a scale of 1-5)	Willing	65,2%	
		Quick service	2,97		More affordable prices or special offers	3,24		Maybe, it depends	23,9%	
		Greater choice of designs and colors	2,95					Not willing	10,9%	
		More professional service	2,86							
		Higher level of hygiene and cleanliness	2,86							
		Better communication	2,67							
		(Scale 1 - 5)								
Touch-points	Experience	Parking	Fast service	Loyalty	Loyalty programs	Special offers	Prices	Premium services	Recommendations	

Source: research

Table 3. Customer Journey Map for Other Users

Stage	**PRE-PURCHASE**									
	Awareness of the salon brand		Selection criteria for choosing a salon	Regularly seeking nail design ideas before visiting the salon	Method of scheduling appointments		Experience with online appointment booking	Potential improvements in the booking process		
Activities	**Salon selection**				**Appointment scheduling**					
Thoughts / Feelings	Stimulating curiosity; Reducing insecurity			Approval; experimentation	Time and care savings					
User Pains	Brand confusion; Risk of wrong choice			Willingness to take risks	Younger clients lack sufficient online options			Concerns about appoint. arrangement		
Objectives	Social media promotion		Reevaluate pricing?	Retain younger clients	Enhance and promote online booking channels			Digitalization; Working hours?		
Situation	Word-of-mouth recommendation	68,6%	1. Service quality and staff expertise	63% fully agree or agree (68.8% among those aged 18-34) Average rating 3.62 (on a scale of 1-5)	SMS / WhatsApp / Viber	39,2%	37.1% have this experience (rating of 3.28 on a scale of 1-4)	Multiple appointments	3,50	
	Through social media	16,7%	2. Cleanliness and salon hygiene		Phone	31,9%		Introduction of the reminder system	3,41	
	Internet searches	6,4%	3. Price and affordability		Other	13,7%		Introduction of online reservations	3,29	
	Regular client of the hair department	2,9%	4. Quick and easy appointment reservation		Through social media	11,8%		Faster response to reservations	3,11	
	Following a favorite manicurist	2,9%	5. Appointment availability		Through online system	3,4%		Working hours	3,05	
	Proximity to the location	2,0%						(Scale 1 - 5)		
	Gift voucher	0,5%								
Touch-points	Social media	Online advertisements	Prices	Appointment availability	Posting new nail designs on social meda	Web applications	Social media	Online booking platform	Reminder application	Working hours

Source: research

Table 3. Customer Journey Map for Other Users – Continued

Stage	**PURCHASE**			**POST-PURCHASE**			
	Experience during the visit	Possible improvements during the visit	Satisfaction with the overall service	Possible improvements after the service is provided	Acceptable price/quality ratio	Willingness to pay for premium services	
Activities	**Nail styling process**			**Usage**			
Thoughts / Feelings	Trust in the quality and expertise of the staff			Are clients satisfied; will they return; recommend the salon to others			
User Pains	:)	Location with more accessible parking?		Regular clients want to be rewarded			
Objectives	Maintain good client experiences			Building loyalty		Consider pricing levels	Offer premium services
Situation	Rated 3,46 (on a scale of 1-4)	Parking 3,24	Rated 4,56 (on a scale of 1-5)	Loyalty program/rewards for loyalty 3,66		Rated 4,18 (on a scale of 1-5)	Willing 64,4%
		Quick service 3,08		More affordable prices or special offers 3,39			Maybe, it depends 22,9%
		Greater choice of designs and colors 3,06					Not willing 12,7%
		More professional service 3,06					
		Higher level of hygiene and cleanliness 3,02					
		Better communication 2,88					
		(Scale 1 - 5)					
Touch-points	Experience	Parking	Fast service	Choice of design and colors	Service	Loyalty programs	Special offers	Premium services	Affordable prices	Recommendations and repurchase

Source: research

The CJMs of the two user groups (Tables 2 and 3) provide an opportunity for a detailed insight into the current state and differences in perceptions between own and other nail salon users based on the empirical research results. In this regard, even minor differences can be observed in the perceptions of own and other users.

In the pre-purchase stage, which involves awareness and salon selection, differences are noticeable in terms of criteria, as price and availability rank fifth for own users and third for other users. Furthermore, own users are less inclined to pre-select nail designs (40% for own users vs. 63% for other users) and are less prone to taking risks in choosing something new. Such results can be attributed to the higher proportion of younger age groups (18-34 years) in the sample (mainly student population) that visit other nail salons, compared to the age structure of own clients.

In the purchase stage (service provision), differences (statistically insignificant) should be highlighted in terms of service experiences, where own users have a slightly better perception (average ratings of 3.76 vs. 3.46 for other users).

In the post-purchase stage, own users are more interested in loyalty programs and rewards (average 3.84 vs. 3.66), and they have fewer complaints about price levels and availability (3.24 vs. 3.39), resulting in higher satisfaction with the price-to-quality ratio (4.65 vs. 4.18).

5. DISCUSSION

CJM serves as a tool for visualizing the decision-making process from the customer's perspective before, during, and after purchasing a service. Therefore, researching customer perceptions of individual touchpoints and the overall customer journey through a questionnaire is an appropriate approach to gaining a realistic view of the current state and issues that need an upgrade or even a redefinition.

CJM, through a separate presentation of its users and other users, provides a helpful comparison with competing salons. In that sense, this paper partially follows the approach of Canfield and Basso (2017: 111), who analyzed the customer journey of three typical couples of restaurant visitors, following the significant differences in demographic characteristics. The comparison results are mostly positive for the case study nail salon, although this information is of secondary importance. The primary goal is to utilize the customer journey visualization from the customers' perspective to improve individual touchpoints and the overall journey further.

The comparison with global research outcomes may confirm the usability of the insights obtained from this research. Pandemic experiences in this industry are reflected in a shift towards ordering systems via online booking platforms and mobile apps. It simultaneously reduces crowd waiting times and better utilizes salon capacities. The millennial group also seeks self-expression and individuality through unique nail designs, colors, and embellishments. Many millennials seek out nail technicians who can create customized and intricate nail art (https://www.grandviewresearch.com). This research also points to the lack of online options (primarily for younger users) and the need to introduce online booking channels. The same applies to the inclination of younger users towards experimenting with new nail designs

6. CONCLUSION AND FUTURE RESEARCH DIRECTIONS

The post-pandemic era brings new challenges and requires service providers to align their processes with potentially permanently altered customer expectations and habits. This task can be quite demanding, especially for small and micro businesses that, despite traditional shortcomings in entrepreneurial and managerial capabilities, must keep up with the pace set by leading global companies, thus shaping consumer experiences, especially those of the younger generation.

In this context, a data-based diagnostic contained in the CJM approach can significantly assist in identifying events that influence consumer frustrations or satisfaction. It also connects customer experiences with specific operational points in the customer journey, required time, or employee interactions. Ultimately, it facilitates the understanding of potential break points in the customer journey (Duncan et al., 2016: 34). Despite some limitations, CJM in this study provides a solid foundation for improving the nail salon's services that served as a case study.

A lack of a more comprehensive investigation into consumers' inclination to recommend their experiences to other existing or potential consumers (either through online or traditional word-of-mouth) was observed regarding future enhancements of this consumer journey research approach.

Additionally, it would be interesting to explore how employee commitment impacts consumer experience, and incorporating theoretical perspectives such as service-dominant (S-D) logic into the study of the consumer experience phenomenon could also yield valuable insights.

REFERENCES

[1] Barnes, S. (2021). The Biggest Nail Trends for 2022, https://stylesage.co/blog/nail-trends-2022, [August, 17th, 2023]

[2] Canfield, D.S. & Basso, K. (2017). Integrating Satisfaction and Cultural Background in the Customer Journey: A Method Development and Test, *Journal of International Consumer Marketing*, 29 (2), pp. 104-117, http://dx.doi.org/10.1080/08961530.2016.1261647

[3] Duncan, E., Fanderl, H., Maechler, N., & Neher, K. (2016). *Customer experience: Creating value through transforming customer journeys*, McKinsey & Company, https://www.mckinsey.com

[4] Følstad, A. & Kvale, K. (2018). Customer journeys: a systematic literature review, *Journal of Service Theory and Practice*, 28 (2), pp. 196-227, https://doi.org/10.1108/JSTP-11-2014-0261

[5] Fornell, C., Morgeson III, F. V, Hult, G. Tomas M, & VanAmburg, D. (2020). *The Reign of the Customer: Customer-Centric Approaches to Improving Satisfaction.* 1st ed, https://doi.org/10.1007/978-3-030-13562-1

[6] Gitnux (2023). Nail Salon Industry 2023: Trends And Statistics, https://blog.gitnux.com/nail-salon-industry-statistics, downloaded: [July, 20th, 2023]

[7] Grand View Research (2023). Nail Salon Market Size, Share & Trends Analysis Report By Service (Manicure, Pedicure), By End-user (Men, Women), By Age Group (Below 18, 19 to 40), By Region (Asia Pacific, North America), And Segment Forecasts, 2023 – 2030, https://www.grandviewresearch.com/industry-analysis/nail-salon-market-report, downloaded: [August, 19th, 2023]

[8] Kalbach, J. (2021). *Mapping Experiences, a Complete Guide to Customer Alignment Through Journeys Blueprints and Diagrams* (2nd edition), O'Reilly Media, Inc., Sebastopol, Kanada

[9] Lee, H. J., Lee, K. H., & Choi, J. (2018). A Structural Model for Unity of Experience: Connecting User Experience, Customer Experience, and Brand Experience. *Journal of Usability Studies*, 14 (1), pp. 8-34

[10] Lemon, K. N., & Verhoef, P. C. (2016). Understanding Customer Experience Throughout the Customer Journey. *Journal of Marketing*, 80(6), pp. 69-96, https://doi.org/10.1509/jm.15.0420

[11] Marquez, J.J., Downey, A., & Clement, R. (2015) Walking a Mile in the User's Shoes: Customer Journey Mapping as a Method to Understanding the User Experience, *Internet Reference Services Quarterly*, 20 (3-4), pp. 135-150, DOI: 10.1080/10875301.2015.1107000

[12] Pantouvakis, A., & Gerou, A. (2022). The Theoretical and Practical Evolution of Customer Journey and Its Significance in Services Sustainability, *Sustainability* 14 (15):9610, pp. 1-16. https://doi.org/10.3390/su14159610

[13] PricewaterhouseCoopers (2023). Perspectives from the Global Entertainment & Media Outlook 2023-2027, https://www.pwc.com/gx/en/industries/tmt/media/outlook/insights-and-perspectives.html, downloaded: [August, 9th, 2023]

[14] Reis, D., Pena, L., & Lopes, P.A. (2003). Customer satisfaction: the historical perspective, *Management Decision*, 41 (2), pp. 195-198.

[15] Waqas, M., Hamzah, Z.L., & Salleh, N.A. (2021). Customer experience: a systematic literature review and consumer culture theory-based conceptualisation. *Management Review Quarterly*, 71, pp. 135-176, https://doi.org/10.1007/s11301-020-00182-w

[16] We Are Social, Hootsuite (2020). Digital 2020: July Global Statshot Report, https://datareportal.com/reports/digital-2020-july-global-statshot, downloaded: [September, 14th, 2022]

[17] We Are Social, Hootsuite (2021). Digital 2021: July Global Statshot Report, https://datareportal.com/reports/digital-2021-july-global-statshot, downloaded: [January, 10th, 2023]

[18] We Are Social, Meltwater (2023a). Digital 2023: July Global Statshot Report https://datareportal.com/reports/digital-2023-july-global-statshot, downloaded: [August, 2nd, 2023]

[19] We Are Social, Meltwater (2023b). Digital 2023 Croatia, The Essential Guide to the Latest Connected Behaviours, https://www.slideshare.net/DataReportal/digital-2023-croatia-february-2023-v01, downloaded: [August, 2nd, 2023]

Preliminary communication / Prethodno priopćenje

MODELIRANJE TROŠKOVA PRIBAVE ZA UNAPRJEĐENJE PRODAJE NEŽIVOTNIH OSIGURANJA

.

izv.prof.dr.sc. **TICIJAN PERUŠKO**
Sveučilište Juraj Dobrila u Puli,
Fakultet ekonomije i turizma „Dr. Mijo Mirković“ Pula
P. Preradovića 1/1,52100 Pula, Hrvatska
tperusko@unipu.hr

DANIJELA PAULIĆ, student
Sveučilište Juraj Dobrila u Puli,
Fakultet ekonomije i turizma „Dr. Mijo Mirković“ Pula
P. Preradovića 1/1,52100 Pula, Hrvatska
dpaulic@student.unipu.hr

SAŽETAK

Cilj istraživanja je razvijanje modela koji će omogućiti predviđanje i upravljanje troškovima pribave i pružiti smjernice za optimizaciju prodajnih aktivnosti u neživotnim osiguranjima. Upravljanje troškovima pribave i unaprjeđenje prodaje predstavlja važan segment u poslovanju osiguravajućih društava kojim se poboljšava učinkovitost poslovanja.

U radu je prikazan model u kojem se primjenom računovodstvenih informacija, statističkih metoda i matematičkih postupaka analiziraju utjecaji troškova pribave na prihode od premija. Kroz iterativni proces, model se kalibrira i usklađuje sa stvarnim podacima. Pomoću ovog modela moguće je simulirati različite scenarije, prilagođavati marketinške aktivnosti i proračunavati očekivane troškove i prihode kako bi se donijele odluke o ulaganjima u unaprjeđenje prodaje.

Da bi se prikazala primjena, procijenila njegova učinkovitost i prognostička točnost testiranje modela provedeno je na realnim podacima iz osiguravajućeg društva. Primjena modela u osiguravajućim društvima omogućuje unaprijeđene poslovnih procesa, donošenje odluka o alokaciji resursa, optimiziranje prodajnih aktivnosti i učinkovitosti prodajnih timova.

KLJUČNE RIJEČI: upravljanje troškovima, unaprjeđenje prodaje, premija osiguranja, troškovi promocije, osiguravajuća društva,

1. UVOD

Industrija osiguranja ima ključnu ulogu u zaštiti pojedinaca, poduzeća i društva od financijskih rizika. Industrija osiguranja dijeli se na segment životnih i segment neživotnih osiguranja. Neživotna osiguranja pružaju zaštitu od gubitka ili oštećenja materijalnih dobara i u pravilu se ugovaraju na rok do godine dana, dok su životna osiguranja višegodišnji ugovori kojima se pruža financijska zaštita uslijed smrti osiguranika. Prodaja polica osiguranja omogućuje

opstojnost osiguravajućih društava na tržištu osiguranja. Jedan od ključnih aspekata koji utječe na prodaju i profitabilnost je efikasno upravljanje troškovima pribave.

Modeliranje troškova pribave za unaprjeđenje prodaje neživotnih osiguranja je pristup koji omogućuje analizu, kvantifikaciju i optimizaciju troškova koji su povezani s marketinškim aktivnostima, prodajnim kanalima, obukom osoblja i drugim relevantnim faktorima u osiguravajućim društvima. Ovaj pristup pruža dublje razumijevanje strukture troškova i omogućuje donošenje odluka o alokaciji resursa i optimizaciji marketinških strategija u cilju postizanja veće prodaje neživotnih osiguranja uz minimiziranje troškova pribave.

Cilj ovog istraživanja je razviti model za modeliranje troškova pribave za unaprjeđenje prodaje neživotnih osiguranja. Kroz analizu različitih faktora istraženi su i identificirani ključni čimbenici koji utječu na troškove pribave. Ti čimbenici integriraju se u model kako bi se procijenila optimalna raspodjela resursa i postigla veća prodaja neživotnih osiguranja uz optimalne troškove pribave.

Važnost modeliranja troškova pribave ogleda se u nekoliko aspekata. Korelacijom troškova pribave i realizirane prodaje omogućuje se detaljnija analiza troškova, analiza utjecaja troškova na rezultate prodaje i uvid u efikasnost marketinških strategija. Simulacijom različitih scenarija identificiraju se najbolje strategije za unaprjeđenje prodaje neživotnih osiguranja. Nadalje, kroz redovito praćenje i analizu troškova pruža se uvid u učinkovitost poslovnih procesa, te omogućuje pravovremeno prilagođavanje procesa kako bi se postigla veća isplativost.

Informacije koje generira model mogu se koristiti za donošenje odluka o marketinškim strategijama i prilagođavati ih u skladu s identificiranim čimbenicima koji utječu na troškove pribave. Rezultati provedenog istraživanja pružaju managementu osiguravajućih društava korisne smjernice za reguliranje prodaje neživotnih osiguranja kroz modeliranje troškova. Integracijom modeliranja troškova pribave i analizom relevantnih faktora pruža se dublje razumijevanje troškova, unaprjeđuju se procesi donošenja odluka o alokaciji resursa i optimizaciji marketinških strategija.

2. PREGLED ISTRAŽIVANJA

Pregled dosadašnjih istraživanja ukazuje na značajan interes za ovu temu u industriji osiguranja. Istraživači su se bavili različitim aspektima troškova pribave i razvijali modele koji pružaju dublje razumijevanje utjecaja tih troškova na prodaju neživotnih osiguranja. U ovom pregledu istraživanja fokusirati ćemo se na neke ključne studije koje su istraživale modeliranje troškova pribave u kontekstu unaprjeđenja prodaje neživotnih osiguranja.

Jedno od važnih istraživanja u ovoj oblasti provedeno je od strane Eling i Luhnen (2010), koji su proučavali troškove i njihov utjecaj na efikasnost osiguravajućih društava. Njihova studija je pokazala da osiguravajuća društva koja učinkovito upravljaju troškovima pribave postižu veću efikasnost. Koristeći modele, identificirali su ključne čimbenike koji utječu na troškove i pružili smjernice za njihovo upravljanje kako bi se postigla veća efikasnost u industriji osiguranja. Također i Chmielowiec-Lewczuk (2019) prikazuje različite vrste troškovnih strategija koje se mogu primijeniti u osiguravajućim društvima u promjenjivim tržišnim uvjetima. Zaključak istraživanja je da oblikovanje troškovnih strategija i instrumenti za postizanje ciljeva zavise o optimizaciji troškova, profitabilnosti, cjenovnoj politici, riziku osiguranja, financijskoj likvidnosti i minimiziranju troškova kapitala. Slično tome, studija

provođena od strane Zalozhnev i Peremezhko (2021) istraživala je efekte povećanja učinkovitosti u upravljanju troškovima pribave. U radu su prikazali modele i aplikativne alate za podršku u upravljanju osiguravajućim društvima. Andrijašević i Petranović (1999) analizirali su troškove poslovanja osiguravajućih društava prema različitim kriterijima. Obradili su troškove prema kriterijima utjecaja na profitabilnost, tekuće i kapitalne troškove, fiksne i varijabilne troškove i troškove koji se uključuju u kalkulaciju premije osiguranja.

Druga važna tema istraživanja u ovom području je analiza utjecaja prodajnih kanala na troškove pribave i prodaju neživotnih osiguranja. Studija koju su proveli Maroofi i suradnici (2017) analizirala je efikasnost prodajnih kanala u osiguravajućim društvima te njihov utjecaj na troškove pribave i prodajne rezultate. Njihovi rezultati pokazuju da je efikasnije upravljanje prodajnim kanalima ključno za smanjenje troškova pribave i povećanje prodaje osiguranja. Matis i Iliesa (2014) proučavali su efekte marketinških troškova na prodaju neživotnih osiguranja. Kroz analizu različitih marketinških strategija razvili su model koji omogućuje optimizaciju alokacije resursa za postizanje najboljih prodajnih rezultata. Njihova studija je ukazala na važnost pravilnog upravljanja troškovima u marketinškim strategijama kako bi se ostvarili planirani ciljevi u prodaji neživotnih osiguranja. Krikel i suradnici (2004) istraživali su područje optimizacije cijena i prihoda osiguranja, a rezultat istraživanja iskazan je u povećanju dobiti kao rezultatu procesa.

Uz to, istraživači su također proučavali utjecaj tehnoloških inovacija na troškove pribave i prodaju neživotnih osiguranja. Capiello (2020) je istraživala primjenu digitalnih alata i tehnologija u prodaji neživotnih osiguranja te njihovu vezu s troškovima pribave. Njezini rezultati ukazuju na potencijal digitalnih inovacija u smanjenju troškova pribave i poboljšanju prodajnih rezultata.

Važno je spomenuti studije koje su se bavile usporedbom različitih modela za modeliranje troškova pribave u industriji osiguranja. Tako, studija izvršena od strane Fang i suradnika (2016) usporedila je različite modele za optimizaciju alokacije resursa u marketinškim aktivnostima osiguravajućih društava. Njihovi rezultati pružaju uvid u prednosti i ograničenja različitih modela i omogućuju osiguravajućim društvima odabir najprikladnijeg modela za njihove specifične potrebe. Istraživanje Lamenta i Bukowskoga (2021) dokazalo je postavljenu hipotezu istraživanja da poslovni model osiguravajućih društava utječe na njihovu financijsku učinkovitost.

Uz to, Moro i Anderloni (2014) prikazuju empirijske dokaze o odrednicama ekonomskih performansi na glavnim europskim tržištima osiguranja. U tu svrhu testirali su utjecaj veličine osiguravajućih društava, troškova poslovanja, strukture kapitala, politike ulaganja i prodaje na ekonomske rezultate za skup društava za neživotno osiguranje koji posluju na glavnim europskim tržištima. Kramarić, Pervan i Ćurak (2022) istraživali su odrednice efikasnosti društva za neživotno osiguranje u Hrvatskoj analizom 18 osiguravajuća društva. Isti autori proveli su istraživanje efikasnosti industrije neživotnog osiguranja prije i nakon ulaska Hrvatske u Europsku uniju i dokazali povećanje ukupne tehničke efikasnosti u sektoru neživotnih osiguranja u razdoblju nakon ulaska Hrvatske u Europsku uniju. Ovi radovi istaknuli su važnost pravilnog upravljanja troškovima pribave, optimizaciju alokacije resursa, primjenu modela i marketinških strategija kako bi se unaprijedio poslovni rezultat u industriji osiguranja.

3. METODOLOGIJA ISTRAŽIVANJA

Regresijska analiza, značajna je i često korištena metoda za analizu podataka, predviđanje i podršku u odlučivanju (Free et. al., 2014.). Freedman (2005) u svom dijelu ističe da regresijski modeli imaju najmanje tri različite namjene i to: sumiranje podataka, predviđanje budućnosti i stvaranje različitih scenarija uvođenjem promjena u varijable. U aplikacijama za prediktivno modeliranje, analiziraju se podaci kako bi se izgradio model koji će se koristiti za procjenu nepoznate varijable koristeći jednu ili više poznatih varijabli. Niz autora istraživalo je regresijske modele od toga se ističu Draper i Smith (1998), Freedman (2005), Frees (2010), Gelman i Hill (2008).

Višestruka regresija je metoda koja se koristi za modeliranje ovisnosti između jedne ovisne varijable i više nezavisnih varijabli. Ova metoda omogućuje analizu svake nezavisne varijable zasebno i njihovu kombiniranu ulogu u objašnjavanju varijabilnosti ovisne varijable. Kod primjene višestruke regresije za modeliranje troškova pribave, cilj je izgraditi statistički model koji najbolje opisuje ovisnost između ovisne varijable i više nezavisnih varijabli. U modeliranju troškova pribave za unaprjeđenje prodaje zavisna varijabla je godišnja bruto premija ostvarena od prodaje neživotnih osiguranja koja se nastoji maksimizirati upravljanjem troškovima pribave. Stoga je u primjeni višestruke linearne regresije vrijednost ovisne varijable izražena visinom godišnje bruto premije, a nezavisne varijable su troškovi pribave. Model se prikazuje kao linearna kombinacija nezavisnih varijabli troškova pribave, gdje svaka varijabla ima svoj regresijski koeficijent.

Primijenjeni model višestruke regresije ima izraz:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \ldots + \beta_k X_k + \varepsilon$$

gdje je:

Y - zavisna varijabla godišnja bruto premija,

β_0, β_1, β_2, β_3... β_n -regresijski koeficijenti

X_1, X_2, X_3... X_n - nezavisne varijable troškovi pribave,

ε - slučajna greška koja predstavlja varijaciju koja nije objašnjena modelom.

Podaci za izradu modela nalaze se u internim računovodstvenim sustavima osiguravajućih društava. Zbog nedostupnosti informacija iz internih računovodstvenih sustava, u ovom su istraživanju, za potrebe prikaza aplikativnosti modela, korištene računovodstvene informacije iz javno objavljenih financijskih izvještaja osiguravajućeg društva.

U izgradnji modela važno je provjeriti pretpostavke višestruke linearne regresije. To uključuje pretpostavke o linearnoj ovisnosti između varijabli, normalnoj distribuciji grešaka, homoskedastičnosti i odsutnosti multikolinearnosti među nezavisnim varijablama. Nakon provjere pretpostavki, slijedi izgradnja modela višestruke linearne regresije. Regresijski koeficijenti β_0, β_1, β_2, β_3... β_n se procjenjuju koristeći metodu najmanjih kvadrata kako bi se minimizirala kvadratna razlika između stvarnih vrijednosti ovisne varijable i predviđenih vrijednosti modela.

Nakon izgradnje modela, potrebno je procijeniti njegovu kvalitetu i pouzdanost. To se postiže procjenom statističke značajnosti regresijskih koeficijenata, analizom varijance i koeficijenta

determinacije. Važno je ocijeniti koliko dobro model objašnjava varijabilnost ovisne varijable bruto premije i kako se nezavisne varijable sačinjene od troškova pribave međusobno povezuju s ovisnom varijablom. Analizom regresijskih koeficijenata utvrđuju se faktori koji najviše utječu na ovisnu varijablu. Pozitivan regresijski koeficijent sugerira pozitivan utjecaj nezavisne varijable na ovisnu varijablu, dok negativan koeficijent ukazuje na negativan utjecaj. Interpretacija rezultata omogućuje donošenje zaključaka o važnosti i smjeru veza među varijablama.

Stoga, metodologija primjene višestruke linearne regresije za modeliranje troškova pribave za unaprjeđenje prodaje neživotnih osiguranja uključuje odabir nezavisnih varijabli, pripremu podataka, izgradnju modela, procjenu regresijskih koeficijenata, evaluaciju modela i validaciju. Korištenje ovog modela omogućuje kvantitativnu analizu i procjenu utjecaja različitih troškovnih faktora na bruto premiju, što je omogućuje optimizaciju prodaje osiguranja. Validacija modela osigurava pouzdanost rezultata i primjenjivost na stvarne podatke.

4. PRIMJENA ISTRAŽIVANJA

Početni podaci korišteni za prikaz aplikativnosti modeliranja troškova pribave preuzeti su iz javno objavljenih financijskih izvještaja osiguravajućeg društva. Radi se o godišnjim vrijednostima bruto premija neživotnih osiguranja i pripadajućim troškovima pribave, sačinjenih od troškova provizija, promocija i plaća u razdoblju od 2010. do 2022. godine.

Tablica 1. Godišnja bruto premija i troškovi pribave osiguravajućeg društva u razdoblju od 2010. do 2022.godine.

(u 000 kn)

Godina	Godišnja bruto premija	Troškovi pribave		
		Provizije	Promocije	Plaće
2010	1.002.530	13.847	47.897	91.885
2011	1.000.382	15.192	42.739	92.578
2012	976.512	14.560	46.878	89.520
2013	970.271	14.268	52.266	88.830
2014	871.324	12.942	33.266	79.764
2015	819.512	12.707	35.605	83.619
2016	842.516	13.977	37.050	83.830
2017	915.180	18.918	37.231	92.421
2018	1.118.862	27.075	38.694	129.761
2019	1.278.989	37.243	39.216	133.095
2020	1.341.591	45.827	40.399	140.818
2021	1.482.142	57.201	41.103	146.659
2022	1.536.610	67.423	44.394	149.881

Izvor: Fina - Registar financijskih izvještaja, https://www.fina.hr/javna-objava (posjećeno 20.08.2023)

U prvom koraku istražuje se veza između godišnjih kretanja troškova pribave i bruto premije upotrebom višestruke regresijske analize. Godišnji troškovi pribave i godišnja bruto premija predstavljaju zbroj svih vrsta neživotnih osiguranja u osiguravajućem društvu. Kod statističkog

modeliranja testirao se odnos nezavisnih varijabli godišnjih troškova pribave sa zavisnom varijablom godišnje bruto premije u analiziranom vremenskom razdoblju.

Tablica 2. Aritmetička sredina i standardna devijacija modela

	Aritmetička sredina	Standardna devijacija	N
Premija	1.088.955,4615	243.029,45725	13
Provizije	27.013,8462	18.867,12221	13
Promocije	41.287,5385	5.401,47766	13
Plaće	107.897,0000	2.7162,85669	13

Izvor: izračun autora prema podacima iz tablice 1.

Tablica 3. Koeficijent multiple korelacije, koeficijent determinacije i prilagođeni koeficijent determinacije modela

Model	R	R^2	Prilagođeni R^2	Standardna pogreška procjene
1	0,991	0,982	0,976	37.531,41095

Izvor: izračun autora prema podacima iz tablice 1

Tablica 2. prikazuje aritmetičku sredinu i standardnu devijaciju po pojedinoj varijabli u obuhvaćenom razdoblju. Koeficijent multiple korelacije, koeficijent i korigirani koeficijent determinacije regresijskog modela prikazani su u tablici 3. Koeficijent korelacije ukazuje na snažnu pozitivnu povezanost varijabli od 0,991. Koeficijent determinacije govori da je 98,20% varijacija u zavisnoj varijabli godišnje bruto premije rezultat varijacija nezavisnih varijabli. Preostalih 1,8 % varijacija u premiji rezultat je pogreške modela, odnosno ne može se pojasniti iz nezavisnih varijabli. Temeljem prikazanog proizlazi pretpostavka da u osiguravajućem društvu postoji znatna povezanost između troškova pribave i godišnje bruto premije, a međupovezanost se može izraziti regresijskim modelom. Ta pretpostavka polazi od činjenice da analizirane računovodstvene informacije predstavljaju zbir svih promatranih vrijednosti osiguravajućeg društava ostvarenih kroz poslovanje na tržištu neživotnih osiguranja.

Tablica 4. Deskriptivna statistika modela ANOVA

Model		Zbroj kvadrata	Stupnjevi slobode	Sredina kvadrata	F	Sig.
1	Protumačena odstupanja	6,961E+11	3	2,320E+11	164,721	0,000[b]
	Neprotumačena odstupanja	1,2677E+10	9	1.408.606.808		
	Ukupna odstupanja	7,088 E+11	12			

Izvor: izračun autora prema podacima iz tablice 1.

F-omjerom testira se statistička značajnost koeficijenta determinacije tako da se uspoređuje dobivena p-vrijednost F-omjera sa p-vrijednosti od 0,05 i time zaključuje da li nezavisna varijabla statistički značajno predviđa zavisnu varijablu. Prema vrijednostima u tablici ANOVA i F-omjera potvrđeno je da postoji statistički značajan doprinos varijacija nezavisnih varijabli troškova pribave u objašnjenu varijacija zavisne varijable bruto premije, te se zaključuje da dobiveni regresijski model statistički predviđa vrijednosti bruto premije.

Tablica 5. Regresijski koeficijenti, t-test i signifikantnost koeficijenata modela

Model		Nestandardizirani koeficijenti		Standardizirani koeficijenti	t	Sig.
		B	St. pogreška	Beta		
1	Konstanta	199.530,3626	118.885,558		1,678	0,128
	Provizije	7,16957	1,707	0,557	4,201	0,002
	Promocije	6,77703	2,008	0,151	3,376	0,008
	Plaće	3,85497	1,185	0,431	3,252	0,010

Izvor: izračun autora prema podacima iz tablice 1.

Jednadžba višestrukog regresijskog modela za modeliranje troškova pribave za unaprjeđenje prodaje neživotnih osiguranja prikazana je nestandardiziranim koeficijentima jer su varijable mjerene istim jedinicama. Regresijski koeficijenti za svaku nezavisnu varijablu prikazani su u tablici. Primjenom pokazatelja t-testa pojedinačno se testira statistička značajnost doprinosa nezavisnih varijabli troškova pribave u regresijskom modelu. P-vrijednosti za sve regresijske koeficijente troškova pribave manje su od 0,001 i stoga se odbacuje nul-hipoteza i potvrđuje da je doprinos svake nezavisne varijable troškova pribave statistički značajan u modelu. Prediktivna sposobnost troškova pribave je opravdana i sve tri nezavisne varijable statistički značajno doprinose modelu.

Model se koristi za predviđanje vrijednosti zavisne varijable godišnje bruto premije na temelju troškova provizije, troškova promocije i troškova plaća. Koeficijent 7,16957 predstavlja utjecaj troškova provizije na godišnju bruto premiju. Ako se troškovi provizije povećaju za jedinicu, očekuje se da će se godišnja bruto premija povećati za 7,16957 tis. kn. Koeficijent 6,77703 predstavlja utjecaj troškova promocije na godišnju bruto premiju. Ukoliko se troškovi promocije povećaju za jedinicu, očekuje se da će godišnja bruto premija povećati za 6,77703 tis. kn. Koeficijent 3,85497 predstavlja utjecaj troškova plaća na godišnju bruto premiju. Ako se troškovi plaća povećaju za jedinicu, očekuje se da će godišnja bruto premija povećati za 3,85497 tis. kn. Koristeći ovaj model, može se predvidjeti godišnja bruto premija na temelju planiranih vrijednosti troškova provizije, troškova promocije i troškova plaća. Također, može se analizirati utjecaj svake nezavisne varijable na godišnju bruto premiju da bi se razumjela njihova važnost u odnosu na ostale faktore.

Tablica 6. Primjena modela sa dvije varijante planskih troškova pribave

(u 000 kn)

Opis	Prethodna 2022. godina	Planska godina			
		Primjer 1.		Primjer 2.	
		Povećanje troškova	Troškovi i premija	Povećanje troškova	Troškovi i premija
Troškovi provizija	67.423,00	1.500,00	68.923,00	1.833,90	69.256,90
Troškovi promocija	44.394,00	1.500,00	45.894,00	2.000,00	46.394,00
Troškovi plaća	149.881,00	1.500,00	151.381,00	-	149.881,00
Godišnja premija	1.536.610,00	-	1.588.273,00	-	1.588.273,00

Izvor: izračun autora

Prethodna tablica prikazuje mogućnost primjene modela sa dva scenarija planskih troškova pribave. Prvi primjer prikazuje planirano povećanje pozicija troškova pribave u odnosu na prethodnu godinu i na osnovu toga je izračunata planska godišnja premija. Takav postupak pogodan je u kreiranju planskih scenarija kombinacijom troškova pribave. U drugom se

primjeru model koristi sa jednom nepoznatom varijablom, a to su troškovi provizije. Naime, uz pretpostavku planiranog godišnjeg povećanja ulaganja u promocije od 2 mil. kn, sa istom razinom troškova plaća iz prethodne godine, uz uvjet realizacije godišnje premije kao u prvom primjeru, potrebno je predvidjeti povećanje prodaje kroz provizijske kanale. Efekti promocije trebali bi se odraziti višom prodajom u provizijskim prodajnim kanalima i utjecati na povećanje troškova provizija za 1.883,90. tis. kn u odnosu na prethodnu godinu i povećati očekivane ukupne godišnje troškove provizije na 69.256,90 tis.kn.

Model ima svoju primjenu u marketingu, financijsko-računovodstvenim analizama, osiguranju, ekonomiji i drugim područjima gdje je važno razumjeti kako troškovi mogu utjecati na prihod i dobit osiguravajućeg društva. Prezentirani model u marketingu ima višestruku primjenu za planiranje proračuna u kojem marketinški tim može analizirati kako promjene u proračunu za različite marketinške aktivnosti utječu na godišnju bruto premiju. Na taj način može se odrediti optimalna raspodjela proračuna između različitih marketinških aktivnosti da bi se postigli najbolji rezultati u povećanju prihoda i profitabilnosti. Nadalje, za predviđanje rezultata marketinških kampanja i to utjecaja na bruto premiju s obzirom na određenu promociju ili marketinšku inicijativu.

Model se može koristiti za identifikaciju najučinkovitijih marketinških strategija gdje se primjenom ovog modela može utvrditi koje varijable troškova pribave imaju najveći utjecaj na bruto premiju. To omogućuje fokusiranje resursa na najučinkovitije marketinške strategije koje doprinose većem povratu ulaganja (ROI). Uz pomoć prezentiranog modela, marketinški tim može analizirati kako se troškovi i bruto premija razlikuju među različitim segmentima tržišta. To omogućuje bolje razumijevanje preferencija i ponašanja različitih skupina kupaca, što može biti korisno pri prilagodbi marketinških strategija za svaki segment neživotnih osiguranja.

U financijsko-računovodstvenim analizama primjena modela pomaže u procjeni utjecaja troškova pribave na bruto premiju. Informacije dobivene modelom omogućavaju identificiranje troškova koji najviše utječu na bruto premiju kako bi se unaprijedilo upravljanje profitabilnošću. Model može pomoći u određivanju adekvatne cijene premije za osiguranje i optimizaciji troškova kako bi se postigla konkurentska prednost na tržištu. Model može poslužiti kao alat za odlučivanje o poslovnim strategijama, gdje na temelju provedene analize management može optimizirati troškove, upravljati premijom i poslovnim rezultatom osiguravajućeg društva.

5. ZAKLJUČAK

Modeliranje troškova pribave za unaprjeđenje prodaje neživotnih osiguranja pristup je koji osiguravajućim društvima omogućuje analizu, kvantifikaciju i optimizaciju troškova koji su povezani s marketinškim aktivnostima, prodajnim kanalima, obukom osoblja i drugim relevantnim faktorima. Ovaj pristup pruža dublje razumijevanje strukture troškova i omogućuje donošenje odluka o alokaciji resursa i optimizaciji marketinških strategija u cilju postizanja veće prodaje neživotnih osiguranja uz minimiziranje troškova pribave. Takav pristup omogućuje managementu osiguravajućih društava da razumiju i analiziraju troškove pribave i steknu uvid u učinkovitost trenutnih marketinških strategija što omogućuje donošenje pravovremenih odluka o alokaciji resursa.

Kroz predstavljeni model mogu se simulirati različiti scenariji kako bi se identificirale najbolje strategije za unaprjeđenje prodaje neživotnih osiguranja uz optimalne troškove pribave, a takav

pristup omogućuje managementu osiguravajućih društava sveobuhvatnije upravljanje poslovnim procesima. Primjenom modela u osiguravajućim društvima poboljšava se učinkovitost prodaje neživotnih osiguranja i time utječe na profitabilnost poslovanja. Na temelju rezultata analize management osiguravajućeg društva može prilagoditi troškove kako bi se povećala bruto premija i poslovni rezultat.

Ograničenje istraživanja ogleda se u tome da se u financijskim izvještajima osiguravajućih društava ne objavljuju informacije o provizijama po prodajnim kanalima, vrste promocija i struktura plaća unutar troškova pribave, što bi omogućilo obuhvat većeg broja varijabli i testiranje utjecaja na bruto premiju. Iz tog razloga su se u prikaz aplikativnosti modela uključile informacije dostupne iz financijskih izvještaja, pa je prijedlog za daljnja istraživanja testiranje modela sa većim brojem troškovnih varijabli koje sačinjavaju troškove pribave.

U cilju razvoja novih znanstvenih spoznaja, istraživanja se primjenom prikazane metodologije mogu provesti po vrstama neživotnih osiguranja. Tim putem mogu se formirati prognostičke analize po vrstama neživotnih osiguranja u promatranim kategorijama. Prikazana metodologija može se primijeniti na osiguravajuća društva i neživotna osiguranja iz drugih zemalja kako bi se testirala primjena i izvršila usporedba sa predmetnim istraživanjem.

REFERENCE

[1] Andrijasevic, S., Petranovic, V. (1999*). Ekonomika osiguranja*, Alfa. Zagreb.

[2] Cappiello, A. (2020). The Digital (R)evolution of Insurance Business Models, *American Journal of Economics and Business Administration* , 1, str. 1-13, 2020.

[3] Chmielowiec-Lewczuk, M. (2019). Cost Strategies Possible to Implement in Insurance Company, *Journal of WEI Business and Economics*, 8, str. 91-97, 2019.

[4] Draper, N. R; Smith H. S. (1998). *Applied Regression Analysis* Wiley, New York, SAD.

[5] Eling, M; Luhnen, M. (2010). Frontier Efficiency Methodologies to Measure Performance in the Insurance Industry: Overview, Systematization, and Recent Developments, . *The Geneva Papers on Risk and Insurance-Issues and Practice*, 35 (2), str. 217-265, 2010.

[6] Fang, K; Jiang Y; Song M. (2016). Customer profitability forecasting using Big Data analytics: A case study of the insurance industry, *Computers & Industrial Engineering*, 101, str. 554-564, 2016.

[7] Fina- Registar financijskih izvještaja, https://www.fina.hr/javna-objava.

[8] Freedman, D. A. (2005). *Statistical Models: Theory and Practice*, Cambridge University Press, New York, SAD.

[9] Frees, E. W. (2010). *Regression Modeling with Actuarial and Financial Applications*, Cambridge University Press, New York, SAD.

[10] Frees, E.W; Derig, A.R; Meyers, G. (2014). *Predictive Modeling Applications in Actuarial Science- Volume I: Predictive Modeling Techniques*, Cambridge University Press New York, SAD.

[11] Gelman, A; J. Hill (2008). *Data Analysis Using Regression and Multilevel/Hierarchical Modeling*, University Press Cambridge, New York, SAD.

[12] Krikler, S; Dolberger, D; Eckel, J. (2004). Method and tools for insurance price and revenue optimisation, *Journal of Financial Services Marketing*, 9 (1), str. 68–79, 2004.

[13] Lament, M; Bukowski, S. (2021). Business Model Impact on the Financial Efficiency of Insurance Companies, *European Research Studies Journal*, 24 (4), str. 327-247, 2021.

[14] Maroofi, F; Ardalan, A.G; Tabarzadi, J. (2017). The Effect of Sales Strategies in the Financial Performance of Insurance Companies, *International Journal of Asian Social Science*, 7(2), str. 150-160, 2017.
[15] Matis, C; Ilies, L. (2014). Customer relationship management in the insurance industry, *Procedia Economics and Finance* , 15, str. 1138 – 1145, 2014.
[16] Moro. O; Anderloni, L. (2014). Non-Life Insurance Economic Performances – An Empirical Investigation, *Journal of Economics and Management*, 18, str.160-177, 2014.
[17] Pavić Kramarić, T; Pervan, M; Ćurak, M. (2022) Determinants of Croatian Non-Life Insurance Companies' Efficiency, *Croatian Operational Research Review*, 13(2), str. 149-16, 2022.
[18] Pervan, M; Ćurak, M; Pavić Kramarić, T. (2021). Has Accession to the European Union Affected the Efficiency of Croatian Insurance Companies*?, International Review of Economics & Business*, 24(1), str. 67-98, 2021.
[19] Zalozhnev, A.Y. & Peremezhko, V.D. (2021). Industrial Insurance Groups Cost Management, *IFAC PapersOnLine*, 54 (13), str. 280–282, 2021.

Review article / Pregledni rad

UČINKOVITOST UI TEHNOLOGIJA PRI GENERIRANJU OGLASNIH PORUKA – EKSPLORATIVNO ISTRAŽIVANJE PERCEPCIJE POTENCIJALNIH KUPACA

BRUNO KRNETA
univ. bacc. oec.
INVENIAM , obrt za kreativne i poslovne usluge
Kuntrada 48, Valbandon
52212 Fažana
bkrneta@inveniam.hr

ERIK RUŽIĆ
Izv.prof.dr.sc.
Sveučilište Jurja Dobrile u Puli
Fakultet ekonomije i turizma „Dr. Mijo Mirković“
Preradovićeva 1/1, 52100 Pula, Hrvatska
erik.ruzic@unipu.hr

SAŽETAK

UI tehnologija, radi jednostavnog korištenja i široke primjene, brzo je ostvarila popularnost kao supstitut za brojne ljudske vještine, uključujući osmišljavanje i kreiranje oglasnih poruka. Načini primjene ove tehnologije već su istraživani za brojne djelatnosti, a prema literaturi koja je analizirana u ovom istraživanju dokazani su brojni pozitivni učinci koji se ostvaruju primjenom UI tehnologije u marketingu i oglašavanju. Međutim, analizirana literatura ne daje odgovor na temeljno istraživačko pitanje – jesu li oglasi kreirani UI tehnologijom učinkovitiji od tradicionalnih oglasa koje su osmislili i kreirali marketinški stručnjaci. Kako bi se utvrdila percepcija oglasnih poruka generiranih UI tehnologijom u odnosu na tradicionalno kreirane oglase, provedeno je eksplorativno istraživanje postupkom eksperimenta, koji se sastojao od oglasa podijeljenih u tri kategorije: video oglasi, tekstualni oglas te statični vizualni oglasi. Svaka kategorija sastojala se od tradicionalnih oglasa i oglasa kreiranih UI tehnologijom, a od ispitanika se zahtijevalo da odaberu onu inačicu za koju smatraju da će ih potaknuti na kupovinu prikazanog proizvoda/usluge. Rezultati istraživanja pokazuju kako je percepcija primatelja oglasa na strani onih oglasa koje su osmislili i kreirali ljudi. Spoznaja nastala rezultatima istraživanja može pridonijeti u ovom aktualnom i nedovoljno istraženom području kao temelj za daljnja istraživanja, odnosno za poboljšanje učinkovitosti oglasnih kampanja koje provode marketinški stručnjaci.

KLJUČNE RIJEČI: umjetna inteligencija, tehnologija, oglasne poruke, percepcija oglasa

EFFECTIVENESS OF AI TECHNOLOGY IN GENERATION OF ADVERTISING MESSAGES - EXPLORATIVE RESEARCH OF THE PERCEPTION OF POTENTIAL BUYERS

ABSTRACT

AI technology, due to its ease of use and wide application, quickly gained popularity as a substitute for many human skills, including designing and creating advertising messages. Ways of applying this technology have already been researched for a number of activities, and according to the literature analyzed in this research, numerous positive effects have been demonstrated that are achieved by the application of AI technology in marketing and advertising. However, the analyzed literature does not provide an answer to the fundamental research question - whether ads created with AI technology are more effective than traditional ads designed and created by marketing experts. In order to determine the perception of ad messages generated by AI technology in relation to traditionally created ads, an exploratory research was conducted using the experimental procedure, which consisted of ads divided into three categories: video ads, text ads, and static visual ads. Each category consisted of traditional ads and ads created with AI technology, and respondents were required to select the version they believed would encourage them to purchase the displayed product/service. The results of the research show that the perception of ad recipients is on the side of those ads designed and created by people. The knowledge gained from the research results can contribute to this current and insufficiently researched area as a basis for further research, i.e. for improving the effectiveness of advertising campaigns carried out by marketing experts.

KEYWORDS: artificial inteligence, technology, advertising messages, ads perception

1. UVOD

Pojava UI tehnologije (UI, eng. Artificial Intelligence – AI) gotovo je disruptivno utjecala na mnoge aspekte poslovanja poduzeća i života ljudi. Dok se s jedne strane ova najnovija tehnološka postignuća mogu usporediti sa revolucionarnim povijesnim otkrićima poput kotača, baruta ili interneta, s druge strane, brzina kojom se UI tehnologija proširila, kako globalno tako i po pitanju funkcionalnosti kojima nadopunjuje dosadašnje aktivnosti ljudskog rada, neusporediva je s bilo kojim dosadašnjim revolucionarnim otkrićem.

Primjena tehnologije umjetne inteligencije već je dostupna u gotovo svim industrijskim sektorima, a unatoč tome što je relativno nova pojava, brojni su autori već istražili implikacije ove tehnologije u djelatnostima poput medicine [Hamet i Tremblay, 2017, Ramesh, et al., 2004], obrazovanja [Zhui, et al., 2021, Guilherme, 2019], transporta [Abduljabbar, et al., 2019] i sigurnosti [Bertino, et al., 2021].

Neupitno je kako su sposobnosti umjetne inteligencije dostatne da konkurira ljudskom umu i radu. Međutim, postavlja se pitanje je li ljudska percepcija na strani tehnologije ili privržena tradicionalnim vrijednostima i empatiji čime se strojno generirana rješenja smatraju „manje vrijednima“. Točnije, u fokusu ovog istraživanja jest ispitivanje učinkovitosti strojno generiranog sadržaja za potrebe promocije proizvoda i usluga. Nadalje, cilj istraživanja je utvrditi percepciju učinkovitosti i preferencije konzumenata oglasa te potencijalnih kupaca,

prema oglasima kreiranim uporabom UI tehnologije u odnosu na one kreirane od strane ljudi, te pronaći odgovor na temeljno istraživačko pitanje – jesu li oglasi generirani UI tehnologijom učinkovitiji od tradicionalno kreiranih oglasa?

Rezultati istraživanja doprinijeti će struci kroz olakšavanje odabira metoda i alata kojima se mogu unaprijediti učinkovitost marketinških komunikacija i strategija, dok će znanosti doprinijeti kroz ostvarenje inicijalnih uvida u ovom novom i nedovoljno istraženom području te će služiti kao temelj za daljnja istraživanja.

Rad se sastoji od pet poglavlja. Nakon uvoda, u drugom se poglavlju daje pregled relevantne literature. U trećem se poglavlju opisuje metodologija istraživanja, te se prezentiraju rezultati provedenog istraživanja. Potom, u četvrtom poglavlju slijedi diskusija te navođenje implikacija istraživanja, nakon čega se, u petom poglavlju daju zaključna razmatranja te se prezentiraju ograničenja provedenog istraživanja kao i preporuke za buduća istraživanja.

2. PREGLED LITERATURE

Iako je UI tehnologija svoju globalnu popularnost ostvarila relativno nedavno, što se može povezati s lansiranjem aplikacije generativne umjetne inteligencije ChatGPT [Aydın i Karaarslan, 2023], ona zapravo nije fenomen 21. stoljeća. Štoviše, prva spominjanja umjetne inteligencije vežu se uz 1959. godinu [Barr, et al., 1981], dok je pojava sve većeg broja znanstvenih rasprava o UI tehnologiji započela je još krajem prošlog stoljeća [Schank, 1987, 1991, Woolf, 1991, Nillson, 1982, Paper, 1988].

Uz najjednostavnije pojašnjenje kako navedena tehnologija predstavlja pokušaj reprodukcije ljudske kognitivne sposobnosti putem računala [Wang, 2008], za sve brojnije implikacije ove tehnologije zaslužno je sve veće povjerenje [Sousa, et al., 2023] koje je tehnologija ostvarila posljednjih godina, što je omogućilo daljnji razvoj i primjenu u sve većem broju djelatnosti i aktivnosti.

Shodno uvriježenom stavu kako je marketing jedan od sektora u kojem inovacije nerijetko pronalaze svoju prvu primjenu [Simmonds, 1986], ova tehnologija već se uvelike koristi pri rješavanju operativnih aktivnosti u domeni marketinga. Primjerice, odgovaranje na upite korisnika, namijenjenih službi za korisnike [Xu, et al., 2020, Buntak, et al., 2020].

Uz jednostavne, sve su brojnije implikacije i u kompleksnim aktivnostima poput analize tržišta te prikupljanja i obrade tržišnih podataka [Overgoor, et al., 2019], upravljanja odnosima s klijetima (CRM9, izrade prediktivnih analiza, predviđanja trendova i izrade marketinških strategija [Buntak, ET AL., 2020], optimizacije korisničkog iskustva, izrade prodajne strategije, cjenovne strategije i strategije distribucije [Campbell, et al., 2020].

Kako je temeljna svrha marketinga, prema definiciji Američkog udruženja za marketing [AMA, 2017], poticanje tržišne razmjene, pitanje je kako UI može izravno doprinijeti temeljnoj svrsi marketinga. Za pronaći odgovor na navedeno pitanje potrebno je krenuti od činjenice da za razmjenu moraju postojati najmanje dva subjekta od kojih je jedan kupac koji je upoznat s postojanjem drugog subjekta, odnosno proizvođača i/ili trgovca. Da bi se potencijalne kupce upoznalo s proizvođačem i ponudom, u suvremenim tržišnim uvjetima koristi se složen skup komunikacijskih aktivnosti koje su objedinjene pod nazivom integrirane marketinške komunikacije [Prpić, 2018].

O načinu primjene i učinkovitosti primjene UI u integriranim marketinškim komunikacijama već su provedena brojna istraživanja [Chen, et al., 2022, Lui i Yu, 2021, Brobbey, et al., 2021, Mo i Yang 2022, Kim, et al., 2021, Deng, et al., 2019].

Lui i Yu [2021] bavili su se fundamentima primjene UI tehnologije u svrhu potpomaganja u kreiranju marketinških komunikacija. Točnije, ustanovili su kako se tržište rada suočava s nedostatkom kvalitetnih talenata koji su dobro upoznati s medijskom industrijom i načinom kreiranja kreativnih sadržaja. Rješenje navedenog problema vide upravo u primjeni UI tehnologije kao pomoćnog alata u razvoju kreativnih strategija i stvaranjukreativnog komunikacijskog sadržaja. Pritom su iznijeli i prijedlog kojim upotreba UI tehnologije treba biti sastavni dio edukacija za navedenu struku.

Brobbey, et al. [2021], proveli su analizu slučaja Jumia Online Ghana, pri čemu su prikupili i obradili podatke o ulozi tehnologije umjetne inteligencije u integriranim marketinškim komunikacijama. Uzorak su sačinjavali klijenti poduzeća i IT stručnjaci zaposleni u organizaciji. Prema rezultatima istraživanja, pokazalo se kako postoji uspješnost UI tehnologija prilikom distribucije oglasa (40% ispitanih je primilo oglasnu poruku) te kako postoji učinkovitost prilikom primjene UI tehnologije s ciljem optimizacije kupčeva putovanja. Točnije, 22% ispitanika se u potpunosti slaže, a 28% njih se slaže, da je kupčevo putovanje bolje nakon implementacije UI tehnologija. U konačnici, iz ovog istraživanja proizlazi zaključak kako je u slučaju promatranog poduzeća UI značajno doprinijela u pogledu generiranja kvalitetnih *leadova* te isporuci promotivnih poruka koje su u skladu s kupčevim preferencijama.

Mo i Yang [2022] bavili su se pitanjima uloge UI tehnologije pri isporuci personaliziranih promotivnih poruka. Točnije, uvidjeli su problem redundanda informacija na internetu koje djeluju negativno u pogledu isporuke poruka sustavima direktnog marketinga. Kao rješenje problema, utvrdili su kako UI tehnologije omogućuju zadovoljavajuću razinu optimizacije informacija o potencijalnim kupcima kao i zadovoljavajuće sustave koji će generirati personalizirane poruke potencijalnim kupcima.

Kim, et al. [2021] ustanovili su postojanje pozitivne reakcije potrošača na preporuke proizvoda koje je generirala UI tehnologija u personaliziranom formatu te su isto utvrdili i na preporuke glazbe s ciljem poticanja kupnje pri čemu su glazbeni prijedlozi također bili odabrani od strane UI tehnologije.

Učinkovitost personaliziranih oglasnih poruka koje su generirane pomoću UI tehnologije utvrdili su i Deng, et al., [2019] te ustanovili kako UItehnologija može biti značajna pomoć kreatorima oglasnih poruka kroz stavljanje veće količine vremena na raspolaganje za kreiranje takvih poruka, dok se UI tehnologija može koristiti u svrhu izrade personaliziranih poruka koje će se isporučivati izravno potrošaču.

Unatoč postojanju brojnih istraživanja o primjeni UI tehnologije u integriranim marketinškim komunikacijama, većina istraživanja ide u smjeru učinkovitosti UI tehnologije prilikom kreiranja i isporuke personaliziranih poruka u vidu izravnog marketinga. Međutim, navedena istraživanja ne daju odgovor na pitanje percepcije oglasne poruke od strane publike, odnosno ostvaruju li bolju učinkovitost oglasi generirani UI tehnologijom ili oni kreirani od strane ljudi.

3. ISTRAŽIVANJE PERCEPCIJE OGLASNIH PORUKA GENERIRANIH UI TEHNOLOGIJOM NASPRAM TRADICIONALNIH OGLASNIH PORUKA

3.1. METODOLOGIJA ISTRAŽIVANJA

Radi jednostavnosti korištenja i široke primjene UI tehnologije, brojne kompanije već su krenule investirati svoja sredstva u takve tehnologije i provoditi digitalnu transformaciju koja je okrenuta upravo UI tehnologiji. Međutim, problem koji takva transformacija može stvoriti jest ulaganje u neučinkovitu tehnologiju. Točnije, problem kojim se bavi ovo istraživanje je nedostatak konkretnih informacija koje pokazuju učinkovitost UI tehnologije prilikom kreiranja oglasnih poruka, a koji se može odraziti na struku kroz donošenje odluka koje nisu u skladu sa stvarni potrebama i preferencijama tržišta. Samim time, cilj ovog istraživanja jest pronaći odgovor na temeljno istraživačko pitanje – koji su, prema percepciji korisnika i potencijalnih kupaca, oglasi učinkovitiji, oni generirani UI tehnologijom ili onikreiranitradicionalno, od strane čovjeka.

Istraživanje percepcije potencijalnih kupaca o učinkovitosti oglasnih poruka kreiranih od strane UI tehnologija u odnosu na tradicionalnoosmišljene i kreirane oglaseprovedeno je kao preliminarnoistraživanjemetodom eksperimenta odnosno testiranjem, te je provedeno pomoću testnog obrasca koji se sastojao od ukupno 18 primjera raspoređenih u 3 skupine. Prva skupina obuhvaćala je oglase u video formatu, druga skupina isključivo tekstualne oglase, dok je treća skupina obuhvaćala statične vizualne oglase. Unutar svake skupine bila su ponuđena 3 para oglasa selektirani prema kriteriju sličnosti, pri čemu je jedan primjerak u paru bio kreiran pomoću UI tehnologije dok je drugi predstavljao tradicionalnu inačicu oglasa, odnosno bio kreiran tradicionalnim metodama i alatima. Ispitanici su birali od svakog para jedanprimjer pri čemu je odabir bio koncipiran u obliku slijepog testa. Točnije, ispitanici prilikom ispunjavanja upitnika nisu bili upoznati s izvorom oglasa niti je li kreiran tradicionalno ili od strane UI tehnologija. Anketni upitnik i svi ponuđeni primjeri bili su na engleskom jeziku. Svi primjeri preuzeti su iz javno dostupnih internetskih izvora, a u drugoj skupini korišten je softverski alat Chat GPT pomoću kojeg su kreirane UI inačice postojećih oglasnih poruka. Struktura obrasca koji se koristio u istraživanju prikazana je u tablici 1.

Tablica 1. Struktura anketnog upitnika

Skupina	Usporedni par	Primjer UI oglasa	Primjer tradicionalnog oglasa
Video oglasi	A	https://www.youtube.com/watch?v=3d47JdoEiAc	https://www.youtube.com/watch?v=nMBBbMN0Nl8
	B	https://www.youtube.com/watch?v=qSewd6Iaj6I	https://www.youtube.com/watch?v=l9xhr4w5XVw
	C	https://www.youtube.com/watch?v=mewB6PS6gZE	https://www.youtube.com/watch?v=8B5WvPtKxtY
Tekstualni oglasi	A	Proslavite našu 4. godišnjicu s nama! Uživajte u ekskluzivnom popustu od 25% na našu kolekciju luksuznih satova. Vremenski ograničena ponuda, prepustite se bezvremenskoj eleganciji danas.	Četiri godine nakon lansiranja, slavimo tako što našim vjernim pratiteljima nudimo 25% popusta na naš prepoznatljiv stil prilikom kreiranja računa. Ekskluzivna ponuda vrijedi od 1. do 5. rujna.
	B	Oslobodite svoju kreativnost uz	Najbolje od Nikea sada će biti

		Nike Customized proizvode, dizajnirane isključivo za vas. Od personaliziranih tenisica do prilagođene odjeće, stvorite stil koji govori mnogo. Naručite sada i neka vaše jedinstvene kreacije budu dostavljene izravno na kućni prag. Poboljšajte svoju igru modom uz Nike Customized.	isporučeno na vaš prag. Prilagodite svoje na www.nike.com
	C	U hotelima Hampton jamčimo čistoću, udobnost i ljubaznu uslugu. Ako vam soba ne odgovara, vratit ćemo vam novac. Doživite bezbrižan boravak u Hamptonu.	Ljubazna usluga, čiste sobe i ugodno okruženje svaki put. Ako niste zadovoljni, ne očekujemo da platite. To je naša obveza i vaše jamstvo. To je 100% Hampton.
Statični vizualni oglasi	A		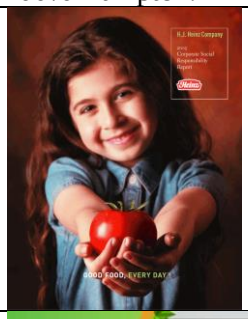
	B		
	C		

Izvor: autori prema: Youtube, Norris [2023], U.S. Securitesand Exchange Commision, Rebelo [2023], Aalho [2022] i Wendys

Upitnik je bio digitalnog formata kreiran u aplikaciji Google Forms te je distribuiran ispitanicima kombinacijom različitihdigitalnih kanala koji su uključivali društvene mreže i izravna distribucija putem e-pošte i platformi za izravno slanje tekstualnih poruka. Distribucija upitnika provedena je u razdoblju od 10. lipnja 2023. godine do 24. kolovoza 2023. godine. U konačnici je istraživanju pristupilo ukupno 165 ispitanika. 67,3% ispitanih izjasnili su se kao pripadnice ženskog spola, njih 31,5% kao pripadnici muškog spola, a 1,2% njih izjasnilo se kao ostalo. Najveći broj ispitanih nalazi se u dobnoj skupini između 25 i 35 godina starosti (njih 49,7%), a zatim slijedi najučestalija dobna skupina od 18 do 24 godina (30,9%). Preostale dobne skupine su od 36 do 45 godina (14,5% ispitanih), 46 do 55 godina (3% ispitanih), ispod 18 godina (1,2%) te iznad 55 godina (0,6%). Po pitanju najvišeg

ostvarenog stupnja obrazovanja, u uzorku su najzastupljeniji oni koji posjeduju sveučilišnu diplomu (47,3%), nakon čega slijede nositelji poslijediplomske diplome (26,7%), nositelji diplome prijediplomskog studija (13,3%). 10,3% ispitanih je navelo kako ima srednjoškolsko obrazovanje kao najviši stupanj obrazovanja, a njih 2,4% ima samo osnovnoškolsko obrazovanje.

3.2. ANALIZA REZULTATA

U prvoj skupini primjera, u kojoj su bili prikazani primjeri video oglasa, u sve tri ponuđene opcije prednost su odnijeli oglasi kreirani tradicionalnim metodama i alatima, odnosno oni koje su u potpunosti kreirali ljudi. Prilikom usporedbe UI video oglasa i tradicionalnih oglasa, u prvom usporednom paru, 57,6% ispitanih odabralo je tradicionalnu inačicu oglasa kao onu za koju vjeruju kako bi ih prije navela na kupovinu prikazanog proizvoda od inačice koju je generirala UI tehnologija. U usporednom paru B,56,40% ispitanih je odabralo tradicionalno kreirani oglas, dok je 43,6% ispitanih odabralo UI generiranu verziju oglasa. U trećoj usporednoj skupini pod oznakom C, 58,2% preferencija odlazi u korist tradicionalno kreiranih video oglasa, dok je 41,8% ispitanih iskazalo svoje preferencije prema UI generiranom oglasu naspram tradicionalno kreiranog oglasa. Usporedba preferencija samih UI oglasa pokazuje kako je najveću razinu preferencija ostvario UI generirani oglas iz prvog usporednog primjera za kojeg je ukupno 70 ispitanih navelo kako smatra da ima veću vjerojatnost navesti ih na kupovinu prikazanog proizvoda u usporedbi s drugim oglasom u istom usporednom primjeru. Gledajući isključivo ovu kategoriju oglasa, iz rezultata istraživanja proizlazi kako tradicionalno kreirani oglasi ostvaruju bolje rezultate glede poticanja potrošača na kupovinu. Odnos između UI video oglasa i tradicionalnih video oglasa prikazan je na grafu 1.

Graf 1. Odnos percepcije UI video oglasa i video oglasa kreiranih tradicionalnim metodama i alatima

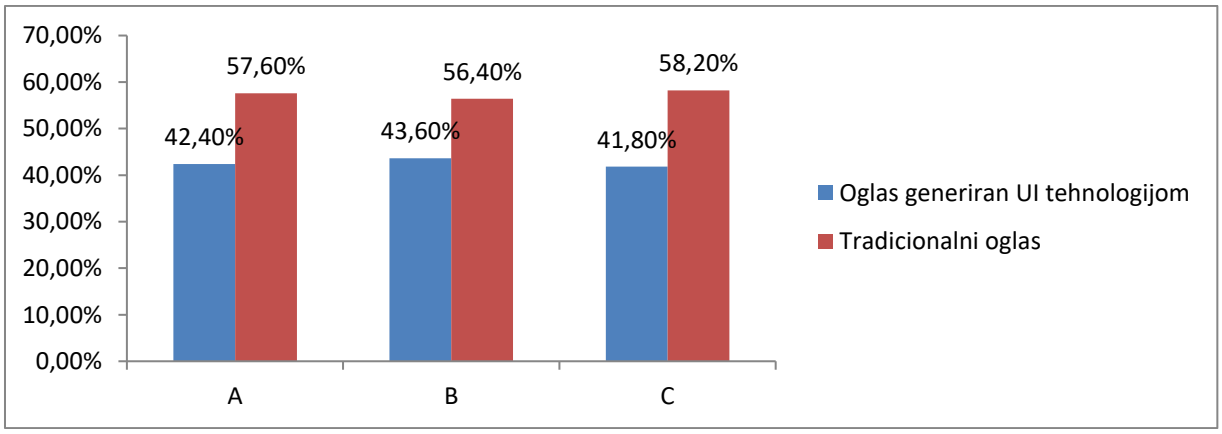

Izvor: autori

U skupini tekstualnih oglasa, preferencije ispitanih su podijeljene. Točnije, u dva slučaja prednost ostvaruju tradicionalno kreirani oglasi, dok u jednoj skupini prednost ostvaruje UI generirani oglas. U pitanju je prva skupina usporednih primjera u kojoj su bili ponuđeni tekstualni oglasi za liniju luksuznih satova čiji brend slavi četvrtu godišnjicu. U toj usporednoj skupini, 60% ispitanih odabralo je UI inačicu kao onu za koju vjeruju kako bi ih prije navela na kupovinu u odnosu na tradicionalno kreiranu inačicu. U usporednoj skupini B, 53,9% ispitanih odabralo je tradicionalno kreirani oglas kao onaj za koji vjeruju kako bi ih prije naveo na kupovinu u odnosu na UI generiranu varijantu koju je odabralo 46,10% ispitanih. U posljednjoj usporednoj skupini tekstualnih oglasa, 55,2% ispitanih odabralo je tradicionalnu inačicu dok je 44,8% ispitanih odabralo UI generiranu verziju oglasa kao onu

prema kojoj imaju više povjerenja glede kupovine proizvoda koji je oglašavan ovom metodom. Odnos preferencija prema UI generiranim tekstualnim oglasima naspram tradicionalno kreiranih tekstualnih oglasa prikazan je na grafu 2.

Graf 2. Odnos percepcije UI generiranih tekstualnih oglasa i tekstualnih oglasa kreiranih tradicionalnim metodama i alatima

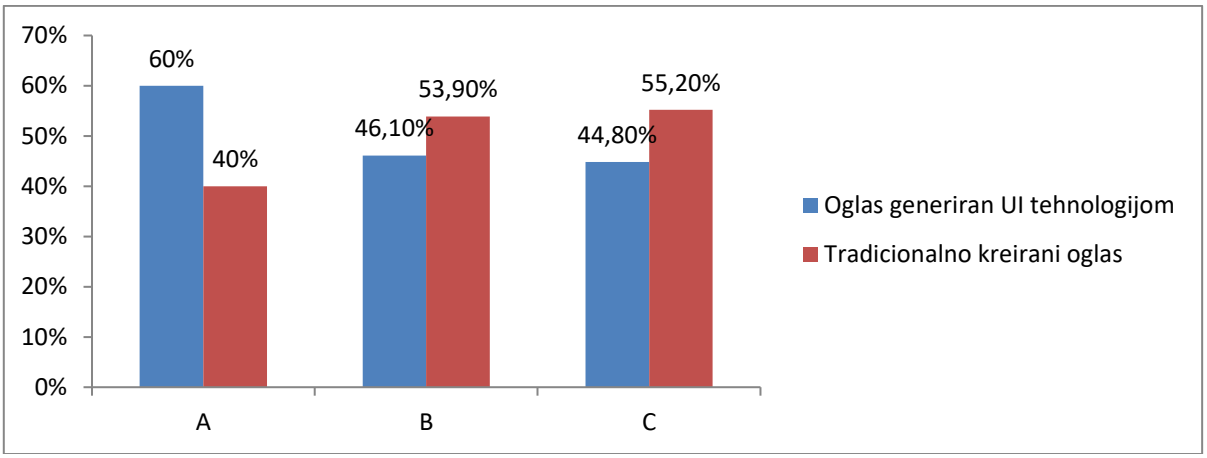

Izvor: autori

U trećoj skupini primjera, u kojoj su se ispitivale preferencije prema statičkim vizualnim oglasima, ostvareni su najbolji rezultati gledajući sa strane UI generiranih oglasa. Točnije, oglas u prvoj usporednoj skupini prikupio je ukupno 122 iskaza preferencija što je više nego li je ikoji od ostalih primjera UI oglasa prikupio. Jednako tako, u ovoj skupini nalazi se i tradicionalno kreirani oglas s najvećim brojem iskaza preferencija te se on nalazi u trećem usporednom primjeru, a za njega se odlučilo 119 ispitanih. Odnos unutar svakog usporednog para je sljedeći: u usporednom paru A, 73,9% ispitanih odabralo je UI varijantu oglasa, 26,1% ispitanih odabralo je tradicionalno kreirani oglas; u usporednom paru B, 43% ispitanih odabralo je UI varijantu oglasa, a 57% ispitanih odabralo je tradicionalno kreirani vizualni oglas; u usporednom paru C, 27,9% ispitanih odabralo je inačicu koju je generirala UI tehnologija, dok je 72,1% ispitanih odabralo tradicionalnu inačicu. Odnos preferencija prema tradicionalnim i UI generiranim statičnim vizualnim oglasima prikazan je na grafu 3.

Graf 3: Odnos percepcije UI generiranih statičnih vizualnih oglasa u odnosu na tradicionalno kreirane statične vizualne oglase

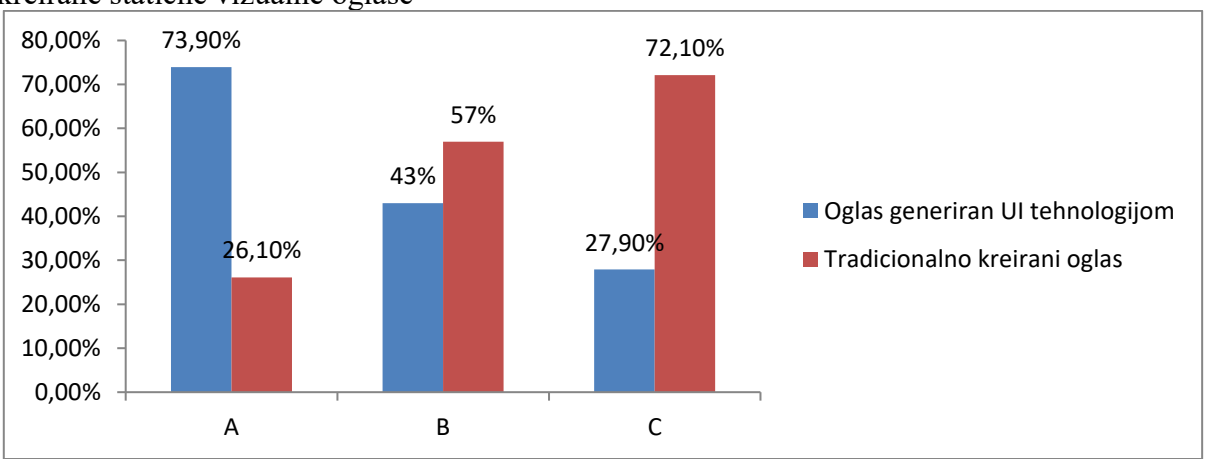

Izvor: autori

Usporedba rezultata ovih triju promatranih skupina pokazuje kako je percepcija ispitanika na strani tradicionalno osmišljenih i kreiranih oglasa. Ipak, određene preferencije ispitanika idu u korist UI generiranih oglasa što pokazuju skupina tekstualnih oglasa i statičnih vizualnih oglasa gdje je po jedan usporedni par prikupio više iskaza preferencija naspram tradicionalno kreiranih oglasa.

4. DISKUSIJA I IMPLIKACIJE PROVEDENOG ISTRAŽIVANJA

Istraživanje percepcije UI generiranih oglasnih poruka naspram tradicionalno osmišljenih i kreiranih oglasnih poruka pokazuje kako su preferencije potrošača i dalje na strani tradicionalno generiranih oglasnih poruka. Navedeno proizlazi iz činjenice kako su ispitanici pokazali veće preferencije prema tradicionalno kreiranim oglasima u svakoj ispitivanoj skupini. Pritom je u prvoj skupini, u kojoj su bili prikazani video oglasi, u svakom usporednom paru većinski postotak glasova ostvarila tradicionalno kreirana inačica oglasa. U preostalim skupinama ispitanici su u 2 usporedna para svoje preferencije usmjerili prema tradicionalno kreiranim oglasima, dok je u skupini tekstualnih oglasa primjer prvog oglasa kreiranog UI tehnologijom ostvario bolje rezultate kao i u 3 skupini gdje su bili prikazani statični vizualni oglasi.

Ovakvi rezultati istraživanja nisu u skladu s zaključcima istraživanja koje su proveli Lui i Yu [2021]. Točnije, iako njihov zaključak kako UI tehnologija ostvaruje uštedu vremena radi čega bi je trebalo aktivno primjenjivati prilikom kreiranja kreativnog sadržaja i prilikom educiranja budućih kreativnih stručnjaka, rezultati ovog istraživanja pokazuju kako takav sadržaj postiže slabije rezultate kod publike. S druge strane, rezultati ovog istraživanja djelomično su u skladu s onima koje su prikupili i analizirali Kim, et al. [2021]. Odnosno, pozitivne reakcije na UI tehnologiju postoje, no kako u ovom istraživanju nije ispitivana glazba, nije prikupljeno dovoljno informacija kako bi se u potpunosti uspostavio zaključak jesu li implikacije UI tehnologije podjednako učinkovite u svim medijskim oblicima koji se koriste u oglašavanju.

Istraživanje je također pokazalo da, iako su preferencije na strani tradicionalno generiranih oglasa, kod većine usporednih parova oglasa razlika u preferencijama iznosi tek nekoliko posto što ukazuje na to da UI generirani oglasi, iako trenutno zaostaju u odnosu na preferencije prema tradicionalnim oglasima, imaju visok potencijal da ostvare vodstvo. Pritom je važno naglasiti kako je u pitanju novo područje u kojem se tek provode preliminarna istraživanja poput ovog, a implikacije ovakvih istraživanja u znanosti i struci mogu dovesti do novih saznanja i značajnijeg poboljšanja izvedbe UI generiranih oglasa.

Točnije, rezultati ovog istraživanja mogu pronaći implikacije i primjenu u struci kroz optimizaciju poslovnih aktivnosti koje su usmjerene osmišljavanju i kreiranju strategija i oglasnih poruka na način da se postigne veća učinkovitost kod ciljne publike i značajne uštede resursa potrebnih za osmišljavanje i kreiranje oglasnih kampanja sukladno istraživanju koje su proveli Deng, et al. [2019]. Drugim riječima, rezultati ovog istraživanja mogu pomoći stručnjacima u postizanju učinkovitijih marketinških kampanja i poboljšanju marketinških strategija, posebice ukoliko se primjene zajedno s implikacijama koje su uočili Brobbey, et al. [2021], a odnose se na dokazanu uspješnost tehnologije UI prilikom isporuke personaliziranih poruka s ciljem prikupljanja *leadova*. Pored navedenog, provedeno eksplorativno istraživanje pridonijeti će i znanosti novim uvidima u nedovoljno istraženom području te isto predstavlja korak u smjeru daljnjih sveobuhvatnijih istraživanja.

5. ZAKLJUČAK

Iako iz istraživanja proizlazi jasan zaključak kako su preferencije potrošača, odnosno percepcije potencijalnih kupaca o učinkovitosti oglasnih poruka i dalje na strani tradicionalno osmišljenih i kreiranih oglasnih poruka, što posebno potvrđuje skupina tekstualnih oglasa za koju se može pretpostaviti kako je mogućnost raspoznavanja izvora najmanja, provedeno istraživanje nosi određena ograničenja koja je preporučljivo otkloniti u budućim istraživanjima. Rezultate provedenog istraživanja svakako je preporučljivo uzeti u obzir prilikom razvoja marketinških strategija i donošenja odluka o alatima koji će se koristiti prilikom osmišljavanja i kreiranja oglasnih materijala.

Ograničenje istraživanja prije svega je uzorak koji je relativno mali. Nadalje, u ispitivanju su sudjelovali samo ispitanici koji imaju pristup internetu i osobnom računalu ili pametnom telefonu, što ograničava spoznaju o načinu percepcije oglasnih poruka one skupine koja oglasne poruke prima isključivo tradicionalnim kanalima u kojima se također može primijeniti UI tehnologija. Nadalje, prilikom istraživanja korišteni su javno dostupni primjeri oglasa što može utjecati na objektivnost prilikom iskazivanja preferencije ukoliko su ispitanici prepoznali izvor oglasa i imaju određene stavove koji se slažu ili prkose s jednim od ispitivanih načina kreiranja oglasa.

Preporuke za buduća istraživanja su svakako korištenje većeg uzorka, provedba ispitivanja u kontroliranim laboratorijskim uvjetima te korištenje istovjetnih promotivnih materijala koji bi omogućili provedbu daljnjih statističkih ispitivanja. Nadalje, u budućim bi istraživanjima bilo uputno koristiti originalne, neobjavljene promotivne materijale koji su kreirani od strane ljudi i UI, za namjenu istraživanja te ispitati druge formate oglasa.

U konačnici, preporuka je ove preliminarne rezultate koristiti kao temelj za provođenje daljnjih ovakvih istraživanja koja će svakako biti potrebna obzirom da je riječ o novoj tehnologiji za koju se mogu očekivati brojne modifikacije koje će voditi prema njezinom usavršavanju što će se odraziti i na konačnu percepciju ispitanika u budućnosti.

REFERENCE

[1] Aalho, J. (2022). Aalho Media, https://aalhomedia.com/ai-generated-images-for-brands/, preuzeto: [08. lipanj 2023]

[2] Abduljabbar, R., Dia, H., Liyanage, S., &Bagloee, S. A. (2019). Applications of artificial intelligence in transport: Anoverview. *Sustainability*, *11*(1), 189.

[3] Aydın, Ö., & Karaarslan, E. (2023). Is Chat GPT leading generative AI? What is beyond expectations?. *What is beyond expectations*.

[4] Barr, A., Feigenbaum, E. A., & Cohen, P. R. (Eds.). (1981). *The handbook of artificial intelligence* (Vol. 1). William Kaufmann.

[5] Bertino, E., Kantarcioglu, M., Akcora, C. G., Samtani, S., Mittal, S., & Gupta, M. (2021, April). AI for Security and Security for AI. In *Proceedings of the Eleventh ACM Conference on Data and Application Security and Privacy* (pp. 333-334).

[6] Brobbey, E. E., Ankrah, E., & Kankam, P. K. (2021). The role of artificial intelligence in integrated marketing communications. A case study of Jumia Online Ghana. *Inkanyiso: Journal of Humanities and Social Sciences*, *13*(1), 120-136.

[7] Buntak, K., Kovačić, M., & Mutavdžija, M. (2021). Application of Artificial Intelligence in the business. *International journal for quality research*, *15*(2), 403.

[8] Campbell, C., Sands, S., Ferraro, C., Tsao, H. Y. J., & Mavrommatis, A. (2020). From data to action: How marketers can leverage AI. *Business Horizons*, *63*(2), 227-243.
[9] Chen, H., Chan-Olmsted, S., Kim, J., & Mayor Sanabria, I. (2022). Consumers perception on artificial intelligence applications in marketing communication. *Qualitative Market Research: An International Journal*, *25*(1), 125-142.
[10] Deng, S., Tan, C. W., Wang, W., & Pan, Y. (2019). Smart generation system of personalized advertising copy and its application to advertising practice and research. *Journal of Advertising*, *48*(4), 356-365.
[11] Guilherme, A. (2019). AI and education: the importance of teacher and student relations. *AI & society*, *34*, 47-54.
[12] Hamet, P., & Tremblay, J. (2017). Artificial intelligence in medicine. *Metabolism*, *69*, S36-S40.
[13] Kim, J., Giroux, M., & Lee, J. C. (2021). When do you trust AI? The effect of number presentation detail on consumer trust and acceptance of AI recommendations. *Psychology & Marketing*, *38*(7), 1140-1155.
[14] Lai, Z., & Yu, L. (2021). Research on digital marketing communication talent cultivation in the era of artificial intelligence. In *Journal of Physics: Conference Series* (Vol. 1757, No. 1, p. 012040). IOP Publishing.
[15] Mo, L., & Yang, L. (2022). Research on application effective evaluation of artificial intelligence technology in marketing communication. *Security and Communication Networks*, *2022*.
[16] Nilsson, N. J. (1982). *Principles of artificial intelligence*. Springer Science & Business Media.
[17] Norris, P. (2023). Social Media Strategies Summit, https://blog.socialmediastrategiessummit.com/10-examples-of-ai-in-marketing/, preuzeto: [08. lipanj 2023]
[18] Overgoor, G., Chica, M., Rand, W., & Weishampel, A. (2019). Letting the computers take over: Using AI to solve marketing problems. *California Management Review*, *61*(4), 156-185.
[19] Papert, S. (1988). One AI ormany?. *Daedalus*, 1-14.
[20] Prpić, T. (2018). Integrirana marketinška komunikacija u željezničkom putničkom prijevozu. Željeznice 21, 17(3), 7-14.
[21] Ramesh, A. N., Kambhampati, C., Monson, J. R., & Drew, P. J. (2004). Artificial intelligencein medicine. *Annals of the Royal College of Surgeons of England*, *86*(5), 334.
[22] Rebelo, M. (2023). Zapier, https://zapier.com/blog/ai-image-examples-for-business/, preuzeto: [08 lipanj 2023]
[23] Schank, R. C. (1987). Whatis AI, anyway?. *AI magazine*, *8*(4), 59-59.
[24] Schank, R. C. (1991). Where's the AI?. *AI magazine*, *12*(4), 38-38.
[25] Simmonds, K. (1986). Marketing as Innovation the eighth paradigm. *Journal of Management Studies*, *23*(5), 479-500.
[26] Sousa, S., Cravino, J., & Martins, P. (2023). Challenges and Trends in User Trust Discourse in AI Popularity. *Multimodal Technologies andInteraction*, *7*(2), 13.
[27] U.S. Securitesand Exchange Commision, https://www.sec.gov/Archives/edgar/data/46640/000095010306001438/dp02734_defa14a.htm, preuzeto: [08. lipanj 2023]
[28] Wang, P. (2008, March). What Do You Mean by "AI"?. In *AGI* (Vol. 171, pp. 362-373).
[29] Wendys, https://www.wendys.com/blog/wendys-newest-frosty-flavors, preuzeto: [08. lipanj 2023]

[30] Whatis Marketing? – TheDefinitionof Marketing, American Marketing Association, https://www.ama.org/the-definition-of-marketing-what-is-marketing/ preuzeto: [10. lipanj 2023]
[31] Woolf, B. (1991). *AI in Education*. University of Massachusetts at Amherst, Department of Computer and Information Science.
[32] Xu, Y., Shieh, C. H., van Esch, P., & Ling, I. L. (2020). AI customer service: Task complexity, problem-solving ability, and usage intention. *Australasian marketing journal*, *28*(4), 189-199.
[33] Youtube, https://www.youtube.com/watch?v=3d47JdoEiAc, https://www.youtube.com/watch?v=qSewd6Iaj6I, https://www.youtube.com/watch?v=mewB6PS6gZE, https://www.youtube.com/watch?v=nMBBbMN0Nl8, https://www.youtube.com/watch?v=l9xhr4w5XVw, https://www.youtube.com/watch?v=8B5WvPtKxtY, preuzeto: [08. lipanj 2023]
[34] Zhai, X., Chu, X., Chai, C. S., Jong, M. S. Y., Istenic, A., Spector, M., ... & Li, Y. (2021). A Review of Artificial Intelligence (AI) in Education from 2010 to 2020. *Complexity*, *2021*, 1-18.

Review article / Pregledni rad

IZVORI INFORMIRANJA KOJI IMAJU NAJVEĆI UTJECAJ NA ODLUKU O KUPNJI PROIZVODA ZA NJEGU „PROBLEMATIČNE“ KOŽE LICA PRIPADNIKA GENERACIJE Z

MIROSLAV MANDIĆ
Sveučilište u Zagrebu
Ekonomski fakultet
Trg J.F. Kennedyja 6, 10000 Zagreb, Hrvatska
mmandic1@net.efzg.hr

SAŽETAK

Cilj rada je bio istražiti izvore informiranja koji imaju najveći utjecaj na odluku o kupnji proizvoda za njegu „problematične“ kože lica pripadnika Generacije Z. Za potrebe rada je kombinirano izviđajno (kvalitativno) i opisno (kvantitativno) istraživanje. U sklopu izviđajnog (kvalitativnog) istraživanja su provedeni dubinski intervjui u kojima je instrument istraživanja bio vodič (podsjetnik za intervju). Provedeno je jednokratno opisno (kvantitativno) istraživanje u kojem je instrument istraživanja bio upitnik. U dubinskim intervjuima je korišten namjerni uzorak, stručnjaka, u kojem je sudjelovalo 5 marketinških menadžera koji upravljaju navedenom kategorijom proizvoda (za njegu „problematične“ kože lica) i/ili se bave istraživanjem tržišta. Uz pretraživanje znanstvenih radova iz ovog područja dubinski intervjui su korišteni kao podloga za pripremu upitnika. Jednokratno opisno (kvantitativno) istraživanje je provedeno na namjernom, prigodnom, uzorku u kojem je sudjelovalo 486 ispitanika. Rezultati pokazuju da su izvori informiranja koji imaju najveći utjecaj na odluku o kupnji proizvoda za njegu „problematične“ kože lica vezani uz ljekarne, pretraživanje interneta (npr. google search) i prijatelji. Nakon navedenih izvora značajan utjecaj još imaju članovi obitelji, utjecajne osobe (influenceri) i instagram. Kao najrjeđi izvor informiranja kod kupnje navedenih proizvoda ispitanici navode web stranice poduzeća (proizvoda), TikTok, YouTube, Internet portale, Facebook, članke u časopisima. Zanimljivi su rezultati koji pokazuju da za ovu kategoriju proizvoda TV, E-mail marketing (Newsletteri), radio i katalozi uopće ne predstavljaju izvor informiranja pri donošenju odluke o kupnji.

KLJUČNE RIJEČI: izvori informiranja, odluka o kupnji, proizvodi za njegu „problematične“ kože lica, Generacija Z

1. UVOD

Cilj rada je bio istražiti izvore informiranja koji imaju najveći utjecaj na odluku o kupnji proizvoda za njegu „problematične“ kože lica pripadnika Generacije Z.
U procesu donošenja odluka o kupnji informacije, izvori informiranja kao i sam proces prikupljanja informacija je jako važan. Informiranje kupaca obično počinje s željom kupca za informacijama i uključuje cijeli niz aktivnosti koje služe dobivanju, obradi, pohranjivanju i dalje prenošenju željenih informacija.

Odabir područja istraživanja rada proizlazi iz dva razloga. Prvi razlog se očituje u činjenici da potreba za informacijama nije ista u svim kategorijama proizvoda, niti kod svih kupaca i kupnji. Drugi razlog je vezan za odabranu kategoriju proizvoda (proizvodi za njegu „problematične“ kože lica) koja je primarno vezana za mlade kupce, odnosno pripadnike Generacije Z koji su prepoznati kao „najveći budući izazov za marketing” [Jiang & Hong, 2023]. Dodatna kompleksnost proizlazi iz činjenice da Generacija Z nije homogena skupina. Primjerice dio autora [Lin, et al., 2013] radi razliku između kupaca po spolu te navode da su žene sklonije online kupnji. S druge strane kada se uzme u obzir kategorija proizvoda, koja je obuhvaćena istraživanjem rada, važan izvor informacija na temelju kojeg kupci donese odluku o kupnju je vezan za ambalažu proizvoda [Abdur Razzaque & Nosheen Chaudhry, 2013].

Postoje brojni čimbenici koji snažno utječu na mlade kao kupce. Najvažniji su [Klemenčić, et al., 2012] obitelj, škola, vršnjaci, kupnja iskustva, odjevna industrija, masovni mediji itd. Potrošači često koriste neformalne i društvene izvore kada traže informacije. Primaju i traže informacije o proizvodu na različitim izvorima, kojih je svakim danom sve više. U posljednjem desetljeću alati informacijske tehnologije doživjeli su ogroman razvoj. Zastupljeni su praktički u svim poslovima [Munkácsi, 2018, Nouri Hussein, et al., 2023]. Kupci često ne obraćaju pozornost na sve informacije kojima su izloženi. Skloni su selektivno obrađivati informacije. Kupci će vjerojatno više obratiti pozornost na informacije koje su u skladu s njihovim početnim stavovima i uvjerenjima [Kim & Yoon, 2023].

2. TEORIJSKI OKVIR

2.1. IZVORI INFORMIRANJA

Proces odlučivanja o kupnji opisuje aktivnosti kroz koje prolazi potrošač kada kupuje proizvode i usluge. Navedeni proces [Nayeem & Casidy, 2013, Mehra & Singh, 2016, Choudhury, et al., 2019, Vranešević, et al., 2021] započinje fazom spoznaje potrebe, a nastavlja se traženjem informacija, vrjednovanjem alternativa, kupnjom i poslijekupovnim ponašanjem.

Proces odlučivanja o kupnji nije isti u svim kategorijama proizvoda, kod svih potrošača niti kod svih kupnji. Iz navedenoga proizlazi jedan od ključnih razloga za pisanje ovoga rada. Faza traženja informacija [Vranešević, et al., 2021, Garner, 2022] počinje nakon spoznavanja potrebe za određenim proizvodom ili uslugom. Razina traženja informacija ovisi o više čimbenika. Pretraživanje informacija definira se kao prikupljanje informacija o mogućim rješenjima prepoznatog problema iz unutarnjih i vanjskih izvora informacija [Hale, et al., 2022]. Traženje informacija najčešće započinje pretraživanje internih podataka koji se nalaze u pamćenju potrošača (interni izvor informacija) [Rickwood & White, 2009, Saha & Sahney, 2022]. Eksterni izvori informacija [Vranešević, et al., 2021] mogu se podijeliti na marketinški (tržišno) orijentirane izvore, osobne izvore i neutralne izvore.
Marketinški izvori informacija su informacije koje su pod kontrolom marketinških stručnjaka kao što su oglasi, promotivni letci, internetska stranica, ambalaža proizvoda i slično. Osobni izvori informacija uključuju svu međuosobnu komunikaciju potrošača koja nije pod utjecajem marketinških stručnjaka u poduzeću, kao što su preporuke prijatelja, recenzije na internetu i slično. Neutralni izvori također nisu pod utjecajem marketinških stručnjaka, a uključuju izvještaje državnih tijela, publikacije nezavisnih agencija i dio masovnih medija [Vranešević, et al., 2021].

Trenutno velik dio procesa traženja informacija zbiva se u digitalnom okruženju gdje na odluku o kupnji utječu različiti izvori informacija kao što su rezultati pretraživanja na internetskim tražilicama, recenzije kupaca [Thomas, et al., 2019], elektronička usmena predaja (eWOM–eword-of-mouth) [Daowd, et al., 2021], informacije na društvenim medijima i službene internetske stranice poduzeća [Vranešević, et al., 2021]. U tom kontekstu najčešće se razlikuju „plaćeni mediji“ (engl. paid media) koje kontrolira poduzeće i „zarađeni mediji“ (engl. earned media). „Plaćeni mediji“ obuhvaćaju aktivnosti koje izravno poduzima poduzeće ili njezini partneri (npr. trgovci na malo), kao što su televizijsko oglašavanje, online oglašavanje ili sponzorstvo. „Zarađeni mediji“ se odnose na neizravni susret s markom, preko drugih kupaca ili trećih strana. Ova kategorija uključuje međusobne interakcije kupaca kao što su WOM [Pires, et al., 2022], recenzije i objavljeni sadržaj (npr. recenzije utjecajnih osoba). Kupci pri traženju informacija koriste više različitih uređaja, nerijetko i istodobno. Informacije o eWOM-u mogu se nazvati bilo kojim oblikom komentara koji imaju veze s proizvodom ili uslugom, koji je dostupan putem interneta [Chen, et al., 2015, Hajli, 2020, Muda & Hamzah, 2021, Song, et al., 2021, Rahaman, et al., 2022, Yang, 2022]. Kako uporaba interneta i online trgovine nastavlja brzi rast kupci dobivaju više prilika za razmjenu znanja i mišljenja o svojim kupnjama. Kupci sada mogu lakše pristupiti tržištu i pretraživati i međusobno dijeliti informacije. Kupci ostavljaju recenzije o proizvodima i uslugama.

Nakon kupnje, kupci često koriste recenzije drugih kako bi procijenili jesu li njihove kupnje bile pravi izbor i na taj način procijenili zadovoljstvo kupnjom [Kim & Yoon, 2023]. S brzim razvojem informacijske tehnologije, preopterećenost informacijama postaje sve češća. Preopterećenost informacijama nastaje kada je količina informacija koju je potrebno obraditi u određenom vremenskom razdoblju veća od kapaciteta obrade informacija kupca. Brojna istraživanja [Hale, et al., 2022, Zhang, et al., 2023] potvrdila su da preopterećenost informacijama ima značajan utjecaj na odluke kupca. Kvaliteta odluka kupaca pozitivno je povezana s količinom informacije koje primaju unutar određenog vremena [Vlašić, et al., 2011]. Kada dođe do preopterećenja informacijama, kvaliteta donošenja odluka značajno opada [Zhang, et al., 2023]. Zbog sve veće količine informacija kupac koji namjerava kupiti proizvod ili uslugu mora odabrati ne samo što kupiti već i koje izvore konzultirati kada traži informacije koje bi mogle pomoći u donošenju odluka [Broilo, et al., 2016]. Sve navedeno ukazuje na izrazitu kompleksnost i potrebu za daljnjim istraživanjima u ovom području što dovodi do istraživačkog pitanja rada: „Koji izvori informiranja imaju najveći utjecaj na odluku o kupnji proizvoda za njegu „problematične“ kože lica?“

2.2. GENERACIJA Z

Generacija Z podrazumijeva rođene između 1995. i 2010. godine. Riječ je o kupcima koji su rođeni u digitalnoj eri i vide pametni telefon svojim najvažnijim internetskim uređajem [Alt & Agárdi, 2023]. Korisnici Generacije Z otvoreniji su prema novim stvarima i rado će testirati nove ideje. Rodriguez et al. [2019] navode da je Generacija Z jedna od najtežih za suradnju, izazovno je uključiti ih u aktivnosti poduzeća te ih nije lako razumjeti. To je generacija koja ima mnogo izbora i koja je nestrpljiva, nisu pretjerano lojalni, brzo i lako mijenjaju proizvode koje kupuju. Pripadnici generacije Z imaju nekoliko defilirajućih karakteristika koje utječu na njihov pogled na svijet i čine ih prepoznatljivima kao članovima društva, ali i radnom snagom.

Članovi ove skupine postajali su punoljetni tijekom ekonomske krize 2007./2008. i velike recesije koja je uslijedila, nakon toga, što utječe na njihov pogled na poduzeća i financije. Ova je generacija također vrlo društveno osviještena [Rodriguez et al., 2019]. Generacija Z je izrazito digitalno usmjerena. Teže jednostavnošću i jasnim, izravnim, uputama. Imaju nisku

toleranciju na pogreške i žele snažno vodstvo što zahtjeva veliku proaktivnost od strane poduzeća. Ismail et al. [2021] ističu da je riječ o generaciji koja nikada nije živjela bez interneta. Kao česti korisnici tehnologije visoko su obrazovani i tehnološki potkovani. Za marketinške stručnjake generacija Z čini se izazovnom jer se ponašaju drugačije od ranijih generacija kao što su generacije Y i X. Primjerice imaju veća očekivanja od svojih omiljenih marki proizvoda; no, također su manje lojalni markama proizvoda i više im je stalo do iskustva. Za generaciju Z, internetski angažman s njihovim omiljenim markama je važan dio njihovih života.

Pripadnici Generacije Z su zanimljivi jer se kroz kupnju i izražavaju. Oni su novi konzervativci koji usvajaju tradicionalna uvjerenja, cijene obitelj, samo kontroliraju se i imaju više odgovornosti. Štoviše, oni mogu utjecati i utječu na kupovne navike svojih roditelja. Pripadnici generacije Z pridaju važnost vrijednosti za novac. Nguyen et al. [2023] da su pripadnici ove generacije vođeni etikom [Martinez & Jaeger, 2016] i uvjerenjima koji su posvećeni pitanjima dobrobiti društva i okoliša više od bilo koje druge generacije. Jiang & Hong [2023] navode da Generacija Z pokazuje nekoliko primjetnih razlika u odnosu na prethodne generacije i prepoznati su kao „najveći budući izazov za marketing". Voljni su potrošiti novac na tehnološke i dizajnerske inovacije. Uvelike se oslanjaju na praktičnost proizvoda, procesa isporuke, iskustvu potrošnje i marketinškim komunikacijama. Nadalje, generacija Z želi sigurnost. Skloni su biti oprezniji i pragmatičniji u trošenju novca, jer su odrasli u ekonomski teškim vremenima. Oni također cijene priliku za bijeg od stresne stvarnosti, kao što je 24-7 pristup društvenim medijima. Osim toga, generacija Z spremna je kupovati i konzumirati ekološki prihvatljive proizvode.

Kaabachi et al. [2022] navode da su pripadnici Generacije Z otvoreni prema korištenju alternativnih pružatelja usluga ako tradicionalni ne uspiju zadovoljiti njihove potrebe i očekivanja. Generacija Z pokazuje drugačije potrebe i očekivanja u usporedbi s drugim generacijama. Imaju velika očekivanja od poduzeća. Cijene kompetentnost, točnost i očekuju personalizirano iskustvo. Drže se tradicionalnih vrijednosti slobode, prijateljstva, zdravlja, etike i transparentnosti. Traže dobru vrijednost za novac. Generacija Z pridaje veću važnost podršci i savjetima, traže personaliziranu uslugu koja će biti pružena putem pametnog telefona [Kaabachi et al., 2022]. Ono što je važno istaknuti je da pripadnici generacije Z nisu homogena skupina i stoga je potrebno kontinuirano provođenje istraživanja tržišta što dodatno ide u prilog ovom radu.

3. METODOLOGIJA ISTRAŽIVANJA

Za potrebe rada je kombinirano izviđajno (kvalitativno) i opisno (kvantitativno) istraživanje. U sklopu izviđajnog (kvalitativnog) istraživanja su provedeni dubinski intervjui u kojima je instrument istraživanja bio vodič (podsjetnik za intervju). Provedeno je jednokratno opisno (kvantitativno) istraživanje u kojem je instrument istraživanja bio upitnik. U dubinskim intervjuima je korišten namjerni uzorak, stručnjaka, u kojem je sudjelovalo 5 marketinških menadžera koji upravljaju navedenom kategorijom proizvoda (za njegu „problematične" kože lica) i/ili se bave istraživanjem tržišta. Intervjui su korišteni za pripremu upitnika. Jednokratno opisno (kvantitativno) istraživanje je provedeno na namjernom, prigodnom, uzorku u kojem je sudjelovalo 486 ispitanika. Prema spolnoj strukturi u uzorku je bilo 13% (64) muškaraca i 86% (418) žena dok je 1% (4) ispitanika uskratilo odgovor na ovaj odgovor. Prema dobi najveći broj ispitanika pripada skupini od 22 do 25 godina (51%, 248), nakon toga slijede ispitanici do 21 godine (27%, 131), zatim od 26 do 30 godina (15%, 75), dok je stariji od 31 godine bilo 7% (32). Iz navedenog se može zaključiti da je struktura uzorka prema dobi u skladu s kategorijom

proizvoda (njega „problematične“ kože lica). Prema učestalosti upotrebe proizvoda za njegu „problematične“ kože lica struktura uzorka je odgovarajuća, jer je u istoj dominiraju ispitanici koji učestalo koriste navedene proizvode (dva puta dnevno 44%, 214, jednom dnevno 24%, 117, dva do tri puta tjedno 12%, 59, itd.). U uzorku dominiraju ispitanici iz Zagreba i okolice (67%, 324, Dalmacija 13%, 64, Sjeverna Hrvatska 8%, 37, Slavonija 8%, 37, Istra, Primorje i Gorski Kotar 4%, 19, Lika i Banovina 1%, 5). što svakako predstavlja jedno od ograničenja ovog istraživanja. Prema kupovnoj moći u strukturi uzorka dominiraju ispitanici koji si mogu priuštiti većina toga (65%, 317, financijska situacija vrlo zadovoljavajuća – možete si priuštiti sve što želite 14%, 66, financijska situacija donekle teška, morate paziti na troškove 16%, 79, financijska situacija vrlo teška – teško pokrivaju osnovne životne troškove 1%, 4, itd.).

Tablica 1. Molimo Vas označite izjave koje se odnose na vas osobno.

Odgovori	Postotak
Izbjegavam kupovati proizvode koji mi ne trebaju.	20,94
Pri izboru proizvoda gotovo uvijek dajem prednost markama koje dobro poznajem.	20,68
Uvijek ću kupiti nešto skuplji proizvod ako znam da će mi pružiti više (na primjer dulje trajanje, lakša upotreba, bolje karakteristike, ...).	19,96
Kad kupujem u stanju sam satima tražiti proizvod koji mi najbolje odgovara.	16,78
Često kupujem proizvode koje preporučuju poznate osobe koje mi se sviđaju.	7,22
Kad kupujem uvijek pazim da proizvod svojim izgledom odgovara mom stilu.	4,16
Prednost gotovo uvijek dajem proizvodima s nižom cijenom.	3,38
Volim kupiti nove predmete iako već imam sličan.	3,38
Često kupujem luksuzne / premium proizvode.	2,73
Volim se okružiti proizvodima koji drugima poručuju kakav je moj položaj u društvu.	0,78
Ukupno	100%

Izvor: Izrada autora

Dodatno obilježje uzorka je da je riječ o ispitanicima koji izbjegavaju kupovati proizvode koji mi ne trebaju, pri izboru proizvoda gotovo uvijek daju prednost markama koje dobro poznaju, spremni su na kupnju nešto skupljih proizvoda ako znaju da će mi pružiti više (na primjer dulje trajanje, lakša upotreba, bolje karakteristike) te su kad kupuju u stanju satima tražiti proizvod koji mi najbolje odgovara.

4. REZULTATI ISTRAŽIVANJA

U istraživanju su ispitanici pitani na koji način se informiraju o proizvodima za njegu „problematične“ kože lica te je vidljivo iz Tablice 7 da ispitanici najviše koriste pretraživanje putem interneta, ljekarne, prijatelje, instagram, a tek nakon toga web stranice marke proizvoda. Ostale izvore u manjoj mjeri koriste pri informiranju o proizvodima za njegu „problematične“ kože lica.

Tablica 2. Na koji način se informirate o proizvodima za njegu „problematične“ kože lica?

Izvor	Postotak
Pretraživanjem interneta (npr. google search)	16,28
Ljekarna	14,52
Preko prijatelja	12,23
Instagram	9,56
Web stranica marke	9,4
Internet portali	6,78
Preko utjecajnih osoba (influencera)	6,67
Preko članova obitelji	6,62
You Tube	5,29
TikTok	4,97
Facebook	2,99
Članci u novinama ili časopisu	1,92
Katalog	1,01
TV	0,91
Putem E-maila (pretplata na newsletter)	0,75
Radio	0,1
Ukupno	100%

Izvor: Izrada autora

Kada je riječ o izvoru informiranja koji ima najveći utjecaj na odluku o kupnji proizvoda za njegu „problematične“ kože lica ispitanici navode da su to primarno ljekarne, pretraživanje putem interneta, prijatelji, članovi obitelji, utjecajne osobe (influencera).

Tablica 3. Za koje od navedenih izvora informiranja biste rekli da imaju najveći utjecaj na Vašu odluku o kupnji proizvoda za njegu „problematične“ kože lica?

Izvor	Postotak
Ljekarna	20,48
Pretraživanjem interneta (npr. google search)	19,64
Preko prijatelja	15,01
Preko članova obitelji	8,56
Preko utjecajnih osoba (influencera)	7,99
Instagram	7,71
Web stranica marke	6,17
TikTok	5,19
You Tube	3,79
Internet portali	2,52
Facebook	1,54
Članci u novinama ili časopisu	1,12
TV	0,14
Putem E-maila (pretplata na newsletter)	0,14
Radio	0
Katalog	0
Ukupno	100%

Izvor: Izrada autora

Kako je u vrhu izvora informiranja pretraživanje interneta ispitanici su pitani zbog kojih razloga koriste Internet kako bi kupili proizvode za njegu „problematične“ kože lica, pa je iz rezultata navedenih u Tablici 4 vidljivo da su primarni razlozi vezani za uštedu novaca (akcije, vaučeri, popusti, promo kodovi), vremena i jednostavnosti.

Tablica 4. Općenito, zbog kojih razloga koristite internet kako biste kupili proizvode za njegu „problematične“ kože lica? Moguće je više odgovora.

Odgovori	Postotak
Akcije, vaučeri, popusti, promo kodovi	16,75
Zbog uštede vremena	15,20
Zbog jednostavnosti	14,37
Kako bi pronašao/la niže cijene	14,01
Imam veći izbor	13,78
Kako ne bi morao/la ići u trgovinu	9,86
Zbog dostave	8,08
Iz navike često kupujem stvari putem interneta	7,60
Nešto drugo	0,35
Ukupno	100%

Izvor: Izrada autora

U Tablici 5 se navode utvrđene statističke značajne razlike pri čemu treba navesti da su ukršteni rezultati iz Tablice 3 (za koje od navedenih izvora informiranja biste rekli da imaju najveći utjecaj na Vašu odluku o kupnji proizvoda za njegu „problematične“ kože lica) sa svim ostalim pitanjima. Statističke značajne razlike nađene su kod spola, dobi, obrazovanja, kupovne moći, regije iz koje ispitanici dolaze i učestalosti korištenja.

Prikupljanje podataka je obavljeno u alatu Qualtrics koji automatski radi ukrštanja i izračun statističkih značajnih razlika prema zadanim varijablama, računajući p vrijednost.

Tablica 5. Statistički značajne razlike

Kriterij	Statistički značajne razlike
Spol	Instagram kao izvor informiranja je značajni ženama.
Spol	Ljekarne kao izvor informiranja više koriste muškarci.
Dob	Za ispitanike mlađe od 18 godina članovi obitelji su značajniji izvor informiranja u usporedbi s ostalim dobnim skupinama.
Obrazovanje	Pretraživanje interneta pri informiranju više koriste visoko obrazovani u odnosu na ispitanike sa završenom srednjom školom.
Obrazovanje	Web stranice marke kao izvor informiranja više koriste ispitanici za završenom srednjom školom nego visoko obrazovni ispitanici.
Kupovna moć	Ispitanici koji moraju paziti na troškove kao izvor informiranja više koriste utjecajne osobe (influencere) nego ostale skupine.
Kupovna moć	Ispitanici koji si mogu priuštiti većinu toga što žele kao izvor informiranja više koriste prijatelje u odnosu na ostale skupine.
Regija	Tik Tok kao izvor informiranja više koriste ispitanici iz Zagreba i okolice i Slavonije u usporedbi s ispitanicama iz Dalmacije.
Regija	Utjecajne osobe (influenceri) su značajni izvor informiranja za ispitanike iz Slavonije u usporedbi s ispitanicama iz Zagreba i okolice.

Učestalost korištenja	Ispitanici koji koriste proizvode za njegu „problematične“ kože 3 i puta više dnevno kao izvor informiranja više koriste Tik Tok nego ostale skupine ispitanika (dva puta dnevno, jednom dnevno, 2-3 puta tjedno).

Izvor: Izrada autora

5. OGRANIČENJA ISTRAŽIVANJA I PREPORUKE ZA BUDUĆA ISTRAŽIVANJA

Ključno ograničenje istraživanja je primjena namjernog, prigodnog, uzorka temeljem kojeg se dobiveni rezultati ne mogu generalizirati na cijelu populaciju. U uzorku dominira ženska populacija, kao i ispitanici iz Zagreba i okolice. Također, prema kupovnoj moći dominiraju ispitanici koji si mogu priuštiti većina toga.

Preporuka za buduća istraživanja bi bila povećati broj muških ispitanika, kao i broj ispitanika iz ostalih regija iz Hrvatske. Također, poželjna bi bila veća zastupljenost ispitanika različitih kupovnih moći. Kako su korišteni stručnjaci u pripremi pitanja za upitnik preporuka bi bila da se stručnjaci iskoriste i u analizi rezultata, odnosno da se kroz kvalitativno istraživanje, putem dubinskih intervjua, a stručnjacima prokomentiraju dobiveni rezultata i stavi veći naglasak na njihovu primjenu u praksi.

6. ZAKLJUČAK

Ispitanici prilikom informiranja o proizvodima za njegu „problematične“ kože lica najviše koriste pretraživanje putem interneta, ljekarne, prijatelje, instagram, a tek nakon toga web stranice marke proizvoda. Ostale izvore u manjoj mjeri koriste pri informiranju o proizvodima za njegu „problematične“ kože lica. Izvori informiranja koji imaju najveći utjecaj na odluku o kupnji proizvoda za njegu „problematične“ kože lica su primarno ljekarne, pretraživanje putem interneta, prijatelji, članovi obitelji, utjecajne osobe (influencera). Razlozi zbog kojih ispitanici koriste internet kako bi kupili proizvode za njegu „problematične“ kože lica vezani su za uštedu novaca (akcije, vaučeri, popusti, promo kodovi), vremena i jednostavnosti.

Statistički značajne razlike nađene su kod spola, dobi, obrazovanja, kupovne moći, regije iz koje ispitanici dolaze i učestalosti korištenja. Instagram kao izvor informiranja je značajni ženama. Ljekarne kao izvor informiranja više koriste muškarci. Za ispitanike mlađe od 18 godina članovi obitelji su značajniji izvor informiranja u usporedbi s ostalim dobnim skupinama. Pretraživanje interneta pri informiranju više koriste visoko obrazovani u odnosu na ispitanike sa završenom srednjom školom. Web stranice marke kao izvor informiranja više koriste ispitanici za završenom srednjom školom nego visoko obrazovni ispitanici. Ispitanici koji moraju paziti na troškove kao izvor informiranja više koriste utjecajne osobe (influencere) nego ostale skupine. Ispitanici koji si mogu priuštiti većinu toga što žele kao izvor informiranja više koriste prijatelje u odnosu na ostale skupine. Tik Tok kao izvor informiranja više koriste ispitanici iz Zagreba i okolice i Slavonije u usporedbi s ispitanicama iz Dalmacije. Utjecajne osobe (influenceri) su značajni izvor informiranja za ispitanike iz Slavonije u usporedbi s ispitanicama iz Zagreba i okolice. Ispitanici koji koriste proizvode za njegu „problematične“ kože 3 i puta više dnevno kao izvor informiranja više koriste Tik Tok nego ostale skupine ispitanika (dva puta dnevno, jednom dnevno, 2-3 puta tjedno).

U skladu s dobivenim rezultatima preporuke za menadžere bi bile da kombiniraju zakup ključnih riječi na tražilicama, ali da je potrebno koristiti integrirani pristup koji će uzeti u obzir i tradicionalne kanale poput ljekarni. Otvara se prostor za različite aktivnosti koje bi mogle uključiti prijatelje potencijalnih kupaca. Primarna društvena mreža je i dalje instagram te bi na nju trebali usmjeriti glavninu aktivnosti. U komunikaciji prema potencijalnim kupcima potrebno je isticati uštedu novaca, vremena i jednostavnosti narudžbi putem interneta. U prodaji treba kombinirati akcije, vaučere, popuste i promo kodove. Kupci proizvoda za njegu „problematične“ kože lica nisu homogena skupina i treba uvažiti spol, dob, obrazovanje, kupovne moću, regiju iz koje ispitanici dolaze kao i učestalost korištenja proizvoda.

REFERENCE

[1] Abdur Razzaque, M., & Nosheen Chaudhry, S. (2013). Religiosity and muslim consumers' decision-making process in a non-muslim society. *Journal of Islamic Marketing*, 4(2), 198-217. https://doi.org/10.1108/17590831311329313

[2] Alt, M., & Agárdi, I. (2023). NFC m-payment as a driver for customer loyalty towards retailers amongst generation Z. *International Journal of Retail & Distribution Management*, 51(3), 347-365. https://doi.org/10.1108/IJRDM-10-2021-0490

[3] Broilo, P. L., Espartel, L. B., & Basso, K. (2016). Pre-purchase information search: Too many sources to choose. *Journal of Research in Interactive Marketing*, 10(3), 193-211. https://doi.org/10.1108/JRIM-07-2015-0048

[4] Chen, C., Nguyen, B., Klaus, P. & Wu, M. (2015). Exploring electronic word-of-mouth (eWOM) in the consumer purchase decision-making process: The case of online holidays - evidence from united kingdom (UK) consumers. *Journal of Travel & Tourism Marketing*, 32(8), 953-970. https://doi.org/10.1080/10548408.2014.956165

[5] Choudhury, N., Mukherjee, S., & Datta, B. (2019). Constrained purchase decision-making process at the base of the pyramid. *The Journal of Consumer Marketing*, 36(1), 178-188. https://doi.org/10.1108/JCM-01-2017-2065

[6] Daowd, A., Hasan, R., Eldabi, T., Rafi-ul-Shan, P. M., Cao, D., & Kasemsarn, N. (2021). Factors affecting eWOM credibility, information adoption and purchase intention on generation Y: A case from thailand. *Journal of Enterprise Information Management*, 34(3), 838-859. https://doi.org/10.1108/JEIM-04-2019-0118

[7] Hajli, N. (2020). The impact of positive valence and negative valence on social commerce purchase intention. *Information Technology & People (West Linn, Or.)*, 33(2), 774-791. https://doi.org/10.1108/ITP-02-2018-0099

[8] Hale, D., Thakur, R., Riggs, J., & Altobello, S. (2022). Consumers' decision-making self-efficacy for service purchases: Construct conceptualization and scale. *The Journal of Services Marketing*, 36(5), 637-657. https://doi.org/10.1108/JSM-12-2020-0505

[9] Garner, B. (2022). An ethnographic analysis of consumer information processing and decision-making at farmers' markets. *The Journal of Consumer Marketing*, 39(1), 66-77. https://doi.org/10.1108/JCM-07-2020-3999

[10] Ismail, A. R., Nguyen, B., Chen, J., Melewar, T. C., & Mohamad, B. (2021). Brand engagement in self-concept (BESC), value consciousness and brand loyalty: A study of generation Z consumers in malaysia. *Young Consumers*, 22(1), 112-130. https://doi.org/10.1108/YC-07-2019-1017

[11] Jiang, Y., & Hong, F. (2023). Examining the relationship between customer-perceived value of night-time tourism and destination attachment among generation Z tourists in

china. *Tourism Recreation Research*, 48(2), 220-233. https://doi.org/10.1080/02508281.2021.1915621

[12] Kaabachi, S., Ben Mrad, S., & Barreto, T. (2022). Reshaping the bank experience for GEN Z in france. *Journal of Marketing Analytics*, 10(3), 219-231. https://doi.org/10.1057/s41270-022-00173-8

[13] Kim, D., & Yoon, Y. (2023). The influence of consumer purchases on purchase-related happiness: A serial mediation of commitment and selective information processing. *Behavioral Sciences*, 13(5), 396. https://doi.org/10.3390/bs13050396

[14] Klemenčič, B., Devetak, G., & Ševančec, D. (2012). Intercultural differences in the purchase and information behaviour of young consumers. *Organizacija*, 45(1), 14-23. https://doi.org/10.2478/v10051-012-0002-8

[15] Lin, X., Featherman, M., Brooks, S. L., & Hajli, N. (2019). Exploring gender differences in online consumer purchase decision making: An online product presentation perspective. *Information Systems Frontiers*, 21(5), 1187-1201. https://doi.org/10.1007/s10796-018-9831-1

[16] Martinez, L. F., & Jaeger, D. S. (2016). Ethical decision making in counterfeit purchase situations: The influence of moral awareness and moral emotions on moral judgment and purchase intentions. *The Journal of Consumer Marketing*, 33(3), 213-223. https://doi.org/10.1108/JCM-04-2015-1394

[17] Mehra, P., & Singh, R. (2016). Consumer preferences and purchase decision-making for micro-packs— an empirical study. *Vision (New Delhi, India)*, 20(3), 224-236. https://doi.org/10.1177/0972262916652806

[18] Muda, M., & Hamzah, M. I. (2021). Should I suggest this YouTube clip? the impact of UGC source credibility on eWOM and purchase intention. *Journal of Research in Interactive Marketing*, 15(3), 441-459. https://doi.org/10.1108/JRIM-04-2020-0072

[19] Munkácsi, N. (2018). The role of knowledge-based consumption in the consumers' purchase decisions of heating products. *Periodica Polytechnica. Social and Management Sciences*, 26(2), 137-148. https://doi.org/10.3311/PPso.11778

[20] Nayeem, T., & Casidy, R. (2013). The role of external influences in high involvement purchase behaviour. *Marketing Intelligence & Planning*, 31(7), 732-745. https://doi.org/10.1108/MIP-02-2013-0030

[21] Nguyen, D. T., Le, D. H. A., Truong, L. G., Truong, N. G., & Vu, V. V. (2023). The effect of generation Z's perceptions of brand activism on brand loyalty: Evidence from vietnam. *Asia Pacific Journal of Marketing and Logistics*, 35(6), 1494-1512. https://doi.org/10.1108/APJML-02-2022-0165

[22] Nouri Hussein, R., Nassreddine, G., & Younis, J. (2023). The impact of information technology integration on the decision-making process. *Journal of Techniques*, 5(1), 144-155. https://doi.org/10.51173/jt.v5i1.1262

[23] Pires, P. B., Santos, J. D., Brito, P. Q. d., & Marques, D. N. (2022). Connecting digital channels to consumers' purchase decision-making process in online stores. *Sustainability (Basel, Switzerland)*, 14(21), 14392. https://doi.org/10.3390/su142114392

[24] Rahaman, M. A., Hassan, H. M. K., Asheq, A. A., & Islam, K. M. A. (2022). The interplay between eWOM information and purchase intention on social media: *Through the lens of IAM and TAM theory*. PloS One, 17(9), e0272926-e0272926. https://doi.org/10.1371/journal.pone.0272926

[25] Rickwood, C., & White, L. (2009). Pre-purchase decision-making for a complex service: Retirement planning. The *Journal of Services Marketing*, 23(3), 145-153. https://doi.org/10.1108/08876040910955152

[26] Rodriguez, M., Boyer, S., Fleming, D., & Cohen, S. (2019). Managing the next generation of sales, gen Z/Millennial cusp: An exploration of grit, entrepreneurship, and loyalty.

Journal of Business-to-Business Marketing, 26(1), 43-55. https://doi.org/10.1080/1051712X.2019.1565136

[27] Saha, M., & Sahney, S. (2022). Exploring the relationships between socialization agents, social media communication, online shopping experience, and pre-purchase search: A moderated model. *Internet Research*, 32(2), 536-567. https://doi.org/10.1108/INTR-08-2020-0472

[28] Shkeer, A. S., & Awang, Z. (2019). The impact of marketing information system components on organizational decision making: A case of jordanian five star hotels. International Review of Management and Marketing, 9(6), 197.

[29] Song, B. L., Liew, C. Y., Sia, J. Y., & Gopal, K. (2021). Electronic word-of-mouth in travel social networking sites and young consumers' purchase intentions: An extended information adoption model. *Young Consumers*, 22(4), 521-538. https://doi.org/10.1108/YC-03-2021-1288

[30] Thomas, M., Wirtz, B. W., & Weyerer, J. C. (2019). determinants of online review credibility and its impact on consumers' purchase intention. *Journal of Electronic Commerce Research*, 20(1), 1-20.

[31] Vlasic, G., Jankovic, M., & Kramo-Caluk, A. (2011). Information hunt: The impact of product type and time pressure on choice of information source for purchase decisions. *Management (Split, Croatia)*, 16(2), 87-103.

[32] Vranešević, T. et al. (2021). *Osnove marketinga*. Ekonomski fakultet Sveučilišta u Zagrebu

[33] Yang, X. (2022). Consumers' purchase intentions in social commerce: The role of social psychological distance, perceived value, and perceived cognitive effort. *Information Technology & People* (West Linn, Or.), 35(8), 330-348. https://doi.org/10.1108/ITP-02-2022-0091

[34] Zhang, G., Cao, J., & Liu, D. (2023). Examining the influence of information overload on consumers' purchase in live streaming: *A heuristic-systematic model perspective*. PloS One, 18(8), e0284466-e0284466. https://doi.org/10.1371/journal.pone.0284466

Review article / Pregledni rad

USE OF CHATGPT AND GPT-4 ARTIFICIAL INTELLIGENCE SYSTEMS IN MARKETING: A REVIEW OF EARLY RESEARCH STUDIES AND PRACTICES

GORAN BUBAŠ
University of Zagreb
Faculty of Organization and Informatics
Pavlinska 2, 42000 Varaždin, Croatia
gbubas@foi.unizg.hr

ANA KUTNJAK
University of Zagreb
Faculty of Organization and Informatics
Pavlinska 2, 42000 Varaždin, Croatia
akutnjak@foi.unizg.hr

ABSTRACT

According to the AI Marketing Benchmark Report 2023 survey, 61.4% of marketing companies have used artificial intelligence (AI) in their marketing activities and 44.4% of them have used AI for content production. Also, the survey published by Intuit Mailchimp in June 2023, revealed that 67% of respondents working in SMB marketing companies believe that "increasing the adoption of marketing automation is essential for acquiring and retaining customers", while 50% of respondents believe that "inadequate AI adoption is holding them back from achieving their goals".

Academic research interest in the application of AI in marketing started in the 1980s, but the number of papers that connect these two fields has begun to considerably increase after 2017. The main focus of our study will be to collect and analyze (a) the most recent articles published in scholarly journals that are specifically addressing the use of AI tools ChatGPT and GPT-4 in marketing, as well as (b) the pre-print and unpublished papers on the same topic. Despite the growing number of articles that are currently addressing the use of these OpenAI tools in marketing (mostly futuristic, and several for instance oriented toward market research, arising ethical concerns, etc.), there is still a lack of quality scholarly research in this area. Therefore, the potentials of ChatGPT, GPT-4 and similar AI tools for their use in practical marketing activities will also be provided in our paper.

KEYWORDS: marketing, artificial intelligence, ChatGPT, GPT-4, review paper

1. INTRODUCTION

The application of artificial intelligence (AI) is expanding with the advancement of technological progress in organizations and the adoption of *Industry 4.0* practices. The benefits of AI have been recognized in various business areas, one of which is marketing, as can be concluded from related

systematic literature reviews (e.g.: [Chintalapati and Pandey, 2022], [Wisetsri et al., 2021], [Verma et al., 2021]). The adoption of AI in marketing can be interpreted in the context of the *diffusion of innovations theory* that was developed by Rogers [2003]. Besides drawing on *technology acceptance theories* regarding customer adoption of AI products (see: [Mehta et al., 2022]) there are several other indicators for tracking the rate of adoption of AI in marketing: (a) increase in the number of related AI products/tools over time; (b) number of business organizations that are using AI tools in marketing; (c) growth in the worldwide market size regarding the use of AI tools in marketing; (d) rising number of published scholarly papers on the use of AI in marketing.

AI can be used in marketing for very different purposes, from the analysis of massive amounts of market/customer data to the automation of customer support and enhancement of customer satisfaction/experience [Abib et al., 2022)]. AI is personalizing marketing activities to better meet customer needs and is also enabling the automation of important components of marketing-related jobs [Haleem et al., 2022a], including the activities of planning, product, pricing, place, and promotion management [Verma, 2021]. Also, AI technology can support organizations in tracking data in real-time and responding quickly to ever-changing customer needs. Furthermore, AI tools are used to predict customer expectations and behavior [Vlačić et al., 2021], making it easier for organizations to plan future business activities [Wisetsri et al., 2021]. From various research [Basha, 2023], [Jabeen, 2022], [Mehta et al., 2022] it is evident that the potential of artificial intelligence and its significance for the rapid development and progress of the field of marketing have been recognized.

Academic research interest in the application of AI in marketing started in the 1980s, but the number of papers that connect these two fields has begun to considerably increase after 2017. The *bibliometric analysis* performed by Ismagiloiva et al. [2020] revealed that the *most frequent keywords* in AI and marketing-related published scholarly papers were associated with neural networks, machine learning, classification, social media and algorithms, while the *largest clusters of topics* were related to the analyses of data collected from the internet (blogs, websites, social media, e-commerce sites). According to De Mauro et al. [2022], the application of AI in marketing remains a relatively new field with various research opportunities. The comprehensive analysis of AI use in marketing by these authors includes a taxonomy of machine learning (ML) applications in marketing that encompasses improvement of: (a) *shopping fundamentals*, e.g., personalization of offers, communication, and recommendations; (b) *consumption experiences*, including products, consumer experience, and services; (c) *decision making*, i.e., market understanding and consumer sensing; and (d) *financial aspects*, e.g., dynamic pricing and media optimization.

A detailed evolution of the research on the use of AI in advertising was presented by Huh et al. [2023]. These authors highlighted several important AI advertising research areas: (a) consumers' experiences of advertising that uses AI; (b) analytical considerations regarding data and algorithms; (c) potential disruptions on the advertising industry; and (d) societal and policy implications regarding the truthfulness of AI-generated content. The conclusion of these authors is that AI is (re)shaping not only the advertising business arena but also advertising research, scholarly writing, and publication policies.

As a recent development in AI, *conversational AI* tools, based on *large language models* – LLMs (see: [Teubner et al., 2023]), like *ChatGPT* and *GPT-4*, have been gaining much popularity after their recent introduction (ChatGPT was launched on November 30, 2022, while GPT-4 was launched on March 14, 2023). A similar LLM tool, *Bard*, which was announced by Google in February 2023, has since been gradually advanced, becoming available for users in various countries, including in Europe, by mid-July 2023. A GPT-4 based tool and search engine, *Bing Chat*, was launched by Microsoft on March 14, 2023. However, despite the growing number of articles that are currently addressing the use of these conversational AI tools in marketing, which are predominantly focused on the use of ChatGPT, published quality research in this area is still

scarce. By identifying some of the main areas of current scholarly papers on the use of ChatGPT in marketing, the authors of this paper aim to make their own contribution to the growing body of literature on this topic.

This paper is structured as follows. After the introductory part, illustrative statistics on the use of AI and ML in marketing are presented. Then, the results of the search for scholarly papers on the use of ChatGPT in marketing and a brief review thereof are presented. The paper ends with the authors' discussion and conclusions related to the topics and content of the uncovered scholarly papers.

2. STATISTICS ON THE USE OF AI AND ML IN MARKETING

In recent years, artificial intelligence has been recognized as one of the most influential business technologies. Having in mind the *adoption of AI in marketing* and the *diffusion of innovations theory* by [Rogers, 2003], in the continuation of this section relevant statistical data is provided.

Vlačić et. al. [2021] predicted that by 2025 the *value of the global AI market* will reach $126 billion in annual revenue. Also, according to the *Statista* portal [Dencheva, 2023], the market value of the *use of AI in marketing* is expected to grow by more than 30% each year, from 12 billion USD in 2021 to 107 billion in 2028. The report by *Inkwood Research* [2021] stated that during the same period AI would predominantly be used for the following marketing applications: search advertising, dynamic pricing, content curation, analytics platforms, social media advertising, virtual assistants, and sales and marketing automation. Also, according to this Inkwood Research report, the end-users of AI in marketing would predominantly come from *retail*, *BFSI* (banking, financial services, insurance), *consumer goods*, *media* and *entertainment* industries.

According to the *AI Marketing Benchmark Report 2023* survey [Geyser, 2023], 61.4% of marketing companies have used artificial intelligence (AI) in their marketing activities, and 44.4% have used AI for content production. Another survey, also conducted in 2023 by *Intuit Mailchimp* [2023], revealed that 67% of respondents working in SMB marketing companies believe that "strategically increasing the adoption of marketing automation is essential for acquiring and retaining customers", while 50% of respondents believe that "inadequate AI adoption is holding them back from achieving their goals".

In the 2022 *Capterra* survey [Bazaman, 2022], 88% of marketers stated that AI or machine learning (ML) software saves their company time and money, while 82% found that the content generated by AI or ML software was as good (or even better!) than the content generated by humans. It is not surprising that the worldwide growth of AI in the specific area of *social media market* was recently predicted to grow from 1.64 billion USD in 2023 to 6.28 billion in 2028 [Mordor Intelligence, 2023].

As stated in the report by *The Conference Board* [Dahlhoff, August 2nd, 2023], a think-tank and business forecasting organization, AI is widely used or experimented with by *marketing* (87%) and *communication* (85%) specialists (N=283), mostly for summarizing content, inspiring thinking, and research. In addition, according to this survey (N=280), most marketing and communication specialists expect that AI tools will improve productivity (85%), even though only 14%-23% of them reported using AI "often" or "all the time".

A more detailed view of the potential *impact on global marketing organizations* by various *generative AI use cases* is provided in an analysis of survey responses by senior executives that was performed by *McKinsey & Company* [Deveau, May 11, 2023]. According to the survey, the estimated ROI/impact was as follows: lead identification (60%), marketing optimization (55%), personalized outreach (53%), dynamic content (50%), up/cross-selling (50%), success analytics

(45%), marketing analytics (45%), dynamic customer-journey mapping (45%), automated marketing workflows (45%), sales analytics (30%), sales coaching (25%). The same survey results also indicate that 90% of the executives responded that their organizations should use generative AI or ML "often" or "almost always". However, most of the surveyed senior executives also responded with "almost never", "rarely", or "sometimes" to the question of how much their organization is using AI (80%) and ML (65%).

Although artificial intelligence affects the improvement of business performance and its benefits are clearly highlighted, research suggests that there is still a lack of AI implementation in marketing processes. As an example, only 20% of marketers have used AI solutions in performing their regular activities [Basha, 2023]. With regard to the fact that AI adoption is influenced by several factors, it is important to note that Elhajjar et al. [2021] found that "67% of marketers do not have the appropriate skills or expertise to implement new technologies such as artificial intelligence". Some authors [Kozinets and Gretzel, 2020] fear that the application of artificial intelligence could cause reductions in the independent recognition of customer needs without the use of advanced tools. Furthermore, research shows that 56% of retailers believe that AI would reduce their creativity [ThinkML, 2023] and that such technology requires large investments and implies high implementation costs. Customer data privacy is another problem that is discussed by several authors (see: [Chintalapati and Pandey, 2022], [Huang and Rust, 2021], [Vlačić et al., 2021]). It is also important to emphasize that, due to changes in customer behavior, marketing systems powered by artificial intelligence must also adapt [Vlačić et al., 2021], with the aim of improving the AI knowledge base and capabilities.

3. APPLICATIONS OF LLM TOOLS IN MARKETING

Recently developed LLMs (like ChatGPT, Whisper, and DALL-E) are being constantly improved, gaining an increasing capability for different tasks [Clark and Perrault, 2023], such as text manipulation, image generation and speech recognition. Also, some of those tools are *publicly available worldwide in a multitude of languages and without any fee*. For instance, as of the end of August 2023 (and tested by the authors of this paper), the widely available *Bing Chat* by Microsoft and *Bard* by Google were, among others, capable of the following: performing a text-based dialogue like a chatbot in a multitude of languages, generating innovative textual content, helping users in writing or optimizing text, translating languages, searching the web for the user, as well as using voice input over the microphone and text-to-speech generation in English for dialogue upon the user's request. In addition, Bing Chat has integrated the *DALL-E* system to create images based on users' descriptions.

When the focus is restricted on conversational AI tools like ChatGPT/GPT-4, Bing Chat, or Bard, only scarce information is available about their actual use cases in marketing. However, recommendations by experts can be found (see: [Islam, 2023]) that include their potential utilization for content creation, search engine optimization (SEO), lead generation (as a chatbot that interacts with site visitors), increase in customer service quality (by use of a chatbot for instant and personalized assistance), audience research (using various types of data), writing product descriptions, social media management, generating customer surveys, generating audience personas, and SWOT analysis. For instance, Haleem et al. [2022b] have analyzed the potential application of ChatGPT in various business fields, including marketing. Also, several authors (e.g.: [Dwivedi et al., 2023a], [Huh et al., 2023], [Peres at al., 2023], [Rivas and Zhao, 2023], [Teubner et al., 2023], etc.) have briefly outlined various potential uses of ChatGPT in marketing and specified related ethical issues.

4. CHATGPT IN SCHOLARLY PAPERS ON MARKETING

From the perspective of the authors of this paper, as a means for tracking the *diffusion of innovation* regarding the use of advanced LLMs in marketing in the first year of their introduction (*GPT 3.5* was introduced in November 2022, *Bard* in February 2023, and *GPT-4* and *Bing Chat* in March 2023), the publishing of related scholarly papers can be observed and analyzed (note: this is also a measure of *diffusion of information* about the *innovation*). For this purpose, a search for scholarly papers with the keywords "ChatGPT" and "GPT" together with "marketing" was performed at the end of August 2023 using various online databases and services for referencing and retrieval of scholarly papers (e.g., IEEE Xplore, ACM Digital Library, Emerald Insight, Google Scholar, arXiv, Web of Science and Scopus). It must be noted that the search with the use of keywords "Google Bard" and "Bing Chat" (or similar combinations) revealed only a few articles that were *not* related to the field of marketing (for instance: [Bhardwaz and Kumar, 2023], [Bull and Kharrufa, 2023]), therefore only the results of literature search with the keywords "ChatGPT" ("GPT") in combination with "marketing" will be presented in this section.

A search for scholarly papers in the *IEEE Xplore* database has yielded only one result with articles that specifically addressed the topic of marketing [Bulut and Mahmoud, 2023]. In the similar *ACM Digital Library* database, only one article [Fukumoto et al., 2021] was found that was related to GPT-2 and marketing. During the search of the *Emerald Insight* database the retrieved articles that were related to ChatGPT and marketing addressed only the specific fields of (a) tourism and hospitality (e.g.: [Dwivedi et al., 2023b], [Carvalho and Ivanov, 2023], [Hartmann and Netzer; 2023], [Ivanov and Soliman; 2023], [Law et al., 2023]) and (b) retail [Kumar et al., 2023].

The search of the *arXiv* database (an open-access archive of mostly pre-published scholarly papers) found only one paper. However, after checking with several detectors for AI-generated text, this paper was found to be not proper for further consideration.

As a result of the search of the *Google Scholar* search engine, numerous published scholarly papers were uncovered (for instance: [Cutler, 2023], [Demir and Demir, 2023], [Haleem et al., 2022b], [Harahap et al., 2023], [Huh et al., 2023], [Keiper, 2023], [Ray, 2023], [Rivas and Zhao, 2023], [Saputra et al., 2023], etc.).

The search of the *Web of Science* and *Scopus* scientific databases with the keywords "ChatGPT" and "GPT" together with "marketing" revealed only several articles that were not mentioned in the previous overview of search results from other databases in this paper: [Abdelkader, 2023], [Dwivedi et al., 2023a], [Paul et al., 2023], and [Peres et al., 2023]. The rather small number of retrieved articles found in these databases is explained by the fact that indexing published scholarly papers in these databases is usually lengthy.

Several relevant papers were also identified using other search methods or were sporadically (accidentally) found while performing searches and checking other retrieved articles on the use of ChatGPT in marketing (for instance: [Brand et al., 2023], [Fusté-Forné and Orea-Giner, 2023]).

5. DISCUSSION

The statistical data and survey results presented in the chapter "Statistics on the use of AI and ML in marketing" indicate that the market for AI and ML products is far from being saturated. Despite the perception of marketers that these tools can increase productivity and revenue, they are insufficiently utilized. In terms of the categories proposed in the *diffusion of innovations theory* by

Rogers [2003], it is mostly the "innovators", "early adopters", and part of the "early majority" that seem to have adopted the use of AI and ML products in marketing.

Less than one year has passed between the time of introduction of ChatGPT (or GPT 3.5) in November 2022 and the and the time of writing the brief review that is presented in this paper. Accordingly, in the context of the scholarly papers on the use of ChatGPT (or GPT-4) in marketing that were retrieved from various scholarly databases (and listed in the preceding chapter), only several publications can be identified with authors who can be categorized as "innovators" (i.e., [Bulut and Mahmoud, 2023], [Brand et al., 2023]) or "early adopters" (i.e., [Carvalho and Ivanov, 2023], [Fusté-Forné and Orea-Giner, 2023]). For instance, Bulut and Mahmoud [2023] used a generative neural network GPT-2 for creating new keywords and new ads in advertising. Also, Brand et al. [2023] have employed GPT 3.5 as a simulator for human responses in virtual tests of customer behavior in the context of market research based on economic theory. Furthermore, Carvalho and Ivanov [2023] have utilized ChatGPT for a summary of tourist reviews, creative generation of themed menu titles and items, and even for defining research agenda for the use of ChatGPT in tourism. Finally, Fusté-Forné and Orea-Giner [2023] have illustrated that ChatGPT can be used as a virtual interviewee and culinary advisor for improvement of gastronomy tourism.

Based on the limited number of retrieved papers on the use of ChatGPT (or GPT-4) in marketing, the following categorization of research foci identified in these papers can be proposed:

- description of ChatGPT potential in marketing and tourism *without examples* (see: [Cutler, 2023], [Dwivedi et al., 2023b], [Harahap et al., 2023], [Hartmann and Netzer, 2023], [Huh et al., 2023], [Ivanov and Soliman, 2023], [Keiper, 2023], [Kumar et al., 2023], [Paul et al., 2023], [Peres et al. 2023], [Ray, 2023], [Rivas and Zhao, 2023], [Teubner et al., 2023]);
- description of ChatGPT potential in specific areas *with practical examples* (e.g.: [Carvalho and Ivanov, 2023], [Fusté-Forné and Orea-Giner, 2023], [Haleem et al., 2023b], [Saputra et al., 2023]);
- description of specific potential of ChatGPT *with empirical research* as support (i.e.: [Abdelkader, 2023], [Demir and Demir, 2023]).

For instance, regarding the description of ChatGPT potential in specific areas *with practical examples*, Haleem et al. [2023] have listed numerous possible practical uses of ChatGPT in business and marketing, while Saputra et al. [2023] have tried to illustrate potential uses of ChatGPT for the improvement of *Instagram marketing*. Regarding the description of specific potential of ChatGPT *with empirical research* as support, Abdelkader [2023] used a *survey* method to investigate the moderating role of customers' comfort and familiarity with technology, business type, and demographic variables (gender, age and education level) on customer experience with ChatGPT and their overall satisfaction in digital marketing. Also, Demir and Demir [2023] used the *interview* method to probe the perceptions of potential positive and negative effects of ChatGPT on tourism business and the tourist industry in general.

When geographical location of the first author is used for categorization of papers, it must be noted that *six* first authors were located in *Europe* (Bulgaria, Germany, Portugal, Spain, and the United Kingdom), *five* first authors were from the *USA*, *five* more first authors were from the *Far East* (India or Indonesia), while *three* first authors were from the *Middle East* (Israel, Saudi Arabia, and Turkey). There were also several papers that were written by co-authors from different countries or world regions. This indicates a *worldwide* scholarly interest in publishing papers on the use of ChatGPT in marketing in the first year after its introduction in November 2022.

It must be emphasized that some of the scholarly papers retrieved on the use of ChatGPT were written in very poor English and were therefore not included in this analysis. However, some papers that had incorrect DOIs or other administrative errors in their description were included in the analysis if the content was of minimal quality. Finally, three retrieved papers on the topic of the use

of ChatGPT in marketing were found to contain text that was indicated as "non-human" or "AI generated" by at least two AI content detectors and were thus not included in this brief review. The authors were able to acquire almost all of the references as *full-text* papers using (a) open-access to published papers, (b) CARNet academic research network and the *Portal of electronic resources for Croatian academic and research community* of the Croatian National and University Library in Zagreb, (c) *ResearchGate* network and community, and (d) other common means for retrieval of online available scholarly documents.

6. CONCLUSION

In less than one year, the industry, scientific community, and the general public have witnessed rapid development and deployment of conversational AI tools based on large language models (LLMs) like ChatGPT/GPT-4, Bard, and Bing Chat. Moreover, technological giants like Apple, Samsung, and Alibaba have also joined the competition in developing tools based on LLMs, while the current ones are undergoing considerable improvements. It is therefore impossible to forecast all the ways that such tools will impact the field of marketing. However, in the near future, it will probably be very much in the form of advancement of the actual uses of AI and ML in marketing, as can be observed from most of the cited papers in our brief review study.

In this paper, the authors concisely outline the main areas of the contemporary use of artificial intelligence and machine learning in marketing and provide the latest statistics on the adoption of such tools and their market share. They also present an overview of scholarly papers published in 2023 on the potential uses of ChatGPT in marketing, along with a categorization of those papers. The authors, however, do not address potential ethical concerns regarding the use of ChatGPT and similar tools in marketing, even though such issues should be seriously taken into account when planning a practical use of these tools in marketing or related fields, including education and research.

REFERENCES

[1] Abdelkader, O.A. (2023). ChatGPT's Influence on Customer Experience in Digital Marketing: Investigating the Moderating Roles. *Heliyon*, 9(8), e18770, https://doi.org/10.1016/j.heliyon.2023.e18770

[2] Abid, H.; Mohd, J.; Mohd, A.Q.; Ravi, P. S.; Rajiv, S. (2022). Artificial Intelligence (AI) Applications for Marketing: A Literature-Based Study. *International Journal of Intelligent Networks*, 3(1), pp. 119–132, https://doi.org/10.1016/j.ijin.2022.08.005

[3] Basha, S.M. (2023). Impact of Artificial Intelligence On Marketing. *East Asian Journal of Multidisciplinary Research*, 2(3), pp. 993-1004, https://doi.org/10.55927/eajmr.v2i3.3112

[4] Bazaman, M. (2022, September). *Does AI Write Better Copy Than Humans? Most Marketers Think So*. Capterra Inc., Arlington, VA, USA, https://www.capterra.com/resources/ai-marketing/ [August 28, 2023]

[5] Bhardwaz, S.; Kumar, J. (2023). An Extensive Comparative Analysis of Chatbot Technologies - ChatGPT, Google BARD and Microsoft Bing. *2nd International Conference on Applied Artificial Intelligence and Computing (ICAAIC)*, pp. 673-679, Salem, India, https://doi.org/10.1109/ICAAIC56838.2023.10140214

[6] Brand, J.; Israeli, A.; Ngwe, D. (2023). *Using GPT for Market Research* (Harvard Business School Marketing Unit Working Paper No. 23–062 and SSRN), https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4395751 [August 28 2023]

[7] Bull, C.; Kharrufa, A. (2023). Generative AI Assistants in Software Development Education: A Vision for Integrating Generative AI Into Educational Practice, Not Instinctively

Defending Against It. *IEEE Software* [Early access], https://doi.org/10.1109/MS.2023.3300574

[8] Bulut, A.; Mahmoud, A. (2023). Generating Campaign Ads & Keywords for Programmatic Advertising. *IEEE Access*, 11, pp. 43557-43565, https://doi.org/10.1109/ACCESS.2023.3269505

[9] Carvalho, I.; Ivanov, S. (2023). ChatGPT for Tourism: Applications, Benefits and Risks. *Tourism Review* [Ahead-of-print], https://doi.org/10.1108/TR-02-2023-0088

[10] Chintalapati, S.; Pandey, S. K. (2022). Artificial Intelligence in Marketing: A Systematic Literature Review. *International Journal of Market Research*, 64(1), pp. 38-68, https://doi.org/10.1177/14707853211018428

[11] Clark, J.; Perrault, R. (2023). Introduction to the AI Index Report 2023. In *Artificial Intelligence Index Report 2023*, Stanford University, Human Centered Artificial Intelligence, https://aiindex.stanford.edu/wp-content/uploads/2023/04/HAI_AI-Index-Report_2023.pdf

[12] Cutler, K. (2023). ChatGPT and Search Engine Optimisation: The Future Is Here. *Applied Marketing Analytics*, 9(1), pp. 8-22, https://www.ingentaconnect.com/contentone/hsp/ama/2023/00000009/00000001/art00002

[13] Dahlhoff, D. (2023, August 2). *AI in Marketing & Communications: Boosting Productivity—and Creativity, Too?* The Conference Board, https://www.conference-board.org/pdfdownload.cfm?masterProductID=48778 [August 28, 2023]

[14] De Mauro, A.; Sestino, A.; Bacconi, A. (2022). Machine Learning and Artificial Intelligence Use in Marketing: A General Taxonomy. *Italian Journal of Marketing*, pp. 439–457, https://doi.org/10.1007/s43039-022-00057-w

[15] Demir, Ş.Ş.; Demir, M. (2023). Professionals' Perspectives on ChatGPT in the Tourism Industry: Does It Inspire Awe or Concern? *Journal of Tourism Theory and Research*, 9(2), pp. 61-77, https://doi.org/10.24288/jttr.1313481

[16] Dencheva, V. (2023). *AI in Marketing Revenue Worldwide 2020-2028*. Statista, Inc., New York, NY, USA / London, UK, https://www.statista.com/statistics/1293758/ai-marketing-revenue-worldwide/ [August 28, 2023]

[17] Deveau, R.; Griffin, S.J.; Rei, S. (2023, May 11). *AI-Powered Marketing and Sales Reach New Heights With Generative AI*. McKinsey & Company, https://www.mckinsey.com/capabilities/growth-marketing-and-sales/our-insights/ai-powered-marketing-and-sales-reach-new-heights-with-generative-ai [August 28, 2023]

[18] Dwivedi, Y.K.; Kshetri, N.; Hughes, L.; Slade, E.L.; Jeyaraj, A.; Kar, A.K.; et al. (2023a). "So What if ChatGPT Wrote It?" Multidisciplinary Perspectives on Opportunities, Challenges and Implications of Generative Conversational AI for Research, Practice and Policy". *International Journal of Information Management*, 71, 102642, https://doi.org/10.1016/j.ijinfomgt.2023.102642

[19] Dwivedi, Y.K.; Pandey, N.; Currie, W.; Micu, A. (2023b). Leveraging ChatGPT and Other Generative Artificial Intelligence (AI)-Based Applications in the Hospitality and Tourism Industry: Practices, Challenges and Research Agenda. *International Journal of Contemporary Hospitality Management* [Ahead-of-print], https://doi.org/10.1108/IJCHM-05-2023-0686

[20] Elhajjar, S.; Karam, M.S.; Borna, S. (2021) Artificial Intelligence In Marketing Education Programs. *Marketing Education Review*, 31(1), pp. 2-13, https://doi.org/10.1080/10528008.2020.1835492

[21] Fusté-Forné, F.; Orea-Giner, A. (2023). Gastronomy in Tourism Management and Marketing: An Interview With ChatGPT. *ROBONOMICS: The Journal of the Automated Economy*, 4, 42, https://journal.robonomics.science/index.php/rj/article/view/42

[22] Fukumoto, K.; Suzuki, R.; Terada, H.; Bato, M.; Nadamoto, A. (2021). Comparison of Deep Learning Models for Automatic Generation of Product Description on E-commerce site. *Proceedings of the 23rd International Conference on Information Integration and Web Intelligence (iiWAS2021)*, pp. 227–235, https://doi.org/10.1145/3487664.3487696

[23] Geyser, W. (2023, February 22). *Artificial Intelligence (AI) Marketing Benchmark Report: 2023*. Influencer Marketing Hub, https://influencermarketinghub.com/ai-marketing-benchmark-report/#toc-0 [August 28, 2023]

[24] Haleem, A.; Javaid, M.; Qadri, M.A.; Singh, R.P.; Suman, R. (2022a). Artificial Intelligence (AI) Applications for Marketing: A Literature-Based Study. *International Journal of Intelligent Networks*, 3, pp. 119-132, https://doi.org/10.1016/j.ijin.2022.08.005

[25] Haleem, A.; Javaid, M.; Singh, R. P. (2022b). An Era of ChatGPT as a Significant Futuristic Support Tool: A Study on Features, Abilities, and Challenges. *BenchCouncil Transactions on Benchmarks, Standards and Evaluations*, 2(4), 100089, https://doi.org/10.1016/j.tbench.2023.100089

[26] Harahap, M.A.K.; Junianto, P.; Astutik, W.S.; Risdwiyanto, A.; Ausat, A.M.A. (2023). Use of ChatGPT in Building Personalisation in Business Services. *Jurnal Minfo Polgan*, 12(1), pp. 1212–1219, https://doi.org/10.33395/jmp.v12i1.12666

[27] Hartmann, J.; Netzer, O. (2023). Natural Language Processing in Marketing. In Sudhir, K. and Toubia, O. (Ed.), *Artificial Intelligence in Marketing (Review of Marketing Research, Vol. 20)*, pp. 191-215., Emerald Publishing Limited, Bingley, https://doi.org/10.1108/S1548-643520230000020011

[28] Huang, M.-H.; Rust, R.T. (2021). A Strategic Framework for Artificial Intelligence in Marketing. *Journal of the Academy of Marketing Science*, 49, pp. 30–50, https://doi.org/10.1007/s11747-020-00749-9

[29] Huh, J.; Nelson, M.R.; Russell, C.A. (2023). ChatGPT, AI Advertising, and Advertising Research and Education. *Journal of Advertising*, 52(4), pp. 477-482, https://doi.org/10.1080/00913367.2023.2227013

[30] Inkwood Research (2021). *Global Artificial Intelligence (AI) In Marketing Market Forecast 2021-2028*. Inkwood Research, Boston, MA, USA / Launceston TAS, Australia, https://inkwoodresearch.com/reports/artificial-intelligence-ai-in-marketing-market/#report-summary [August 28, 2023]

[31] Intuit Mailchimp (2023, June 13). *Intuit Mailchimp Finds Vast Majority of SMB Marketers Are Bought Into Artificial Intelligence*. The Rocket Science Group, Atlanta, GA, USA, https://mailchimp.com/intuit-mailchimp-finds-vast-majority-of-smb-marketers-are-bought-into-ai/ [August 28, 2023]

[32] Islam, A. (2023, June 30). *10 Use Cases of ChatGPT in Marketing for 2023*. Marktechpost Media Inc., https://www.marktechpost.com/2023/06/30/10-use-cases-of-chatgpt-in-marketing-for-2023/ [August 28th, 2023]

[33] Ismagiloiva, E.; Dwivedi, Y.K.; Rana, N. (2020). Visualising the Knowledge Domain of Artificial Intelligence in Marketing: A Bibliometric Analysis. In: Sharma, S.K., Dwivedi, Y.K., Metri, B., Rana, N.P. (eds), *Re-imagining Diffusion and Adoption of Information Technology and Systems: A Continuing Conversation. TDIT 2020. IFIP Advances in Information and Communication Technology*, vol. 617. Springer, Cham, https://doi.org/10.1007/978-3-030-64849-7_5

[34] Ivanov, S.; Soliman, M. (2023). Game of Algorithms: ChatGPT Implications for the Future of Tourism Education and Research. *Journal of Tourism Futures*, 9(2), pp. 214-221, https://doi.org/10.1108/JTF-02-2023-0038

[35] Jabeen, M. (2022). The Use of AI in Marketing: Its Impact and Future. *World Journal of Advanced Research and Reviews*, 16(03), pp. 730–733, https://doi.org/10.30574/wjarr.2022.16.3.1419

[36] Keiper, M. C. (2023). ChatGPT in Practice: Increasing Event Planning Efficiency Through Artificial Intelligence. *Journal of Hospitality, Leisure, Sport & Tourism Education*, 33, 100454, https://doi.org/10.1016/j.jhlste.2023.100454

[37] Kozinets, R. V.; Gretzel, U. (2020). Commentary: Artificial Intelligence: The Marketer's Dilemma. *Journal of Marketing*, 85(1), pp. 156–159, https://doi.org/10.1177/0022242920972933

[38] Kumar, A.; Gupta, N.; Bapat, G. (2023). Who Is Making the Decisions? How Retail Managers Can Use the Power of ChatGPT. *Journal of Business Strategy*, [Ahead-of-print], https://doi.org/10.1108/JBS-04-2023-0067

[39] Law, R.; Lin, K.J.; Ye, H.; Fong, D.K.C. (2023). Artificial Intelligence Research in Hospitality: A State-Of-The-Art Review and Future Directions. *International Journal of Contemporary Hospitality Management*, [Ahead-of-print], https://doi.org/10.1108/IJCHM-02-2023-0189

[40] Mehta, P.; Jebarajakirthy, C.; Maseeh, H. I.; Anubha, A.; Saha, R.; Dhanda, K. (2022). Artificial Intelligence in Marketing: A Meta-Analytic Review. *Psychology & Marketing*, 39, pp. 2013–2038, https://doi.org/10.1002/mar.21716

[41] Mordor Intelligence (2023). *Artificial Intelligence (AI) in Social Media Market Size & Share Analysis - Growth Trends & Forecasts (2023 - 2028)*. Mordor Intelligence, Hyderabad, Telangana, India, https://www.mordorintelligence.com/industry-reports/ai-market-in-social-media [August 28, 2023]

[42] Paul, J.; Ueno, A.; Dennis, C. (2023). Chatgpt and Consumers: Benefits, Pitfalls and Future Research Agenda. *International Journal of Consumer Studies*, 47(4), pp. 1213-1225, https://doi.org/10.1111/ijcs.12928

[43] Peres, R.; Schreier, M.; Schweidel, D.; Sorescu, A. (2023). On ChatGPT and Beyond: How Generative Artificial Intelligence May Affect Research, Teaching, And Practice. *International Journal of Research in Marketing*, 40(2), pp. 269-275, https://doi.org/10.1016/j.ijresmar.2023.03.001

[44] Ray, P.P. (2023). ChatGPT: A Comprehensive Review on Background, Applications, Key Challenges, Bias, Ethics, Limitations and Future Scope. *Internet of Things and Cyber-Physical Systems*, 3, pp. 121–154, https://doi.org/10.1016/j.iotcps.2023.04.003

[45] Rivas, P.; Zhao, L. Marketing with ChatGPT: Navigating the Ethical Terrain of GPT-Based Chatbot Technology. *AI*, 4(2), pp. 375-384, https://doi.org/10.3390/ai4020019

[46] Rogers, E. (2003*). Diffusion of Innovations*, 5th Edition. Free Press / Simon and Schuster, New York, NY, USA

[47] Saputra, R.; Nasution, M. I. P.; Dharma, B. (2023). The Impact of Using AI Chat GPT on Marketing Effectiveness: A Case Study on Instagram Marketing. *Indonesian Journal of Economics and Management*, 3(3), pp. 603-617, https://jurnal.polban.ac.id/ojs-3.1.2/ijem/article/view/4936

[48] Teubner, T.; Flath, C.M.; Weinhardt, C.; van der Aalst, W.; Hinz, O. (2023). Welcome to the Era of ChatGPT et al.: The Prospects of Large Language Models. *Business & Information Systems Engineering*, 65, pp. 95–101, https://doi.org/10.1007/s12599-023-00795-x

[49] ThinkML (2023). *The Dark Side of AI in Marketing: Understating the Disadvantages*, https://thinkml.ai/the-dark-side-of-ai-in-marketing/ [August 28, 2023]

[50] Verma, S.; Sharma, R.; Deb, S.; Maitra, D. (2021). Artificial Intelligence in Marketing: Systematic Review and Future Research Direction. *International Journal of Information Management Data Insights*, 1(1), Article 100002, https://doi.org/10.1016/j.jjimei.2020.100002

[51] Vlačić, B.; Corbo, L.; de Silva, S. C.; Dabić, M. (2021). The Evolving Role of Artificial Intelligence in Marketing: A Review and Research Agenda. *Journal of Business Research*, 128, pp. 187-203, https://doi.org/10.1016/j.jbusres.2021.01.055

[52] Wisetsri, W.; Ragesh T.; Aarthy, C. J.; Thakur, V.; Pandey, D.; Gulati, K. (2021). Systematic Analysis and Future Research Directions in Artificial Intelligence for Marketing. *Turkish Journal of Computer and Mathematics Education*, 12(11), pp. 43-55, https://doi.org/10.17762/turcomat.v12i11.5825

Review article / Pregledni rad

DIGITALNI NOMADI – ISTRAŽIVANJE NA PRIMJERU POTENCIJALA GRADA SPLITA I NJEGOVE OKOLICE

ZORAN MIHANOVIĆ
Sveučilište u Splitu
Ekonomski fakultet
Cvite Fiskovića 5, 21000 Split, Hrvatska
zoran.mihanovic@efst.hr

NIKOLA JUKIĆ
Sveučilište u Splitu
Ekonomski fakultet
Cvite Fiskovića 5, 21000 Split, Hrvatska
njukic01@live.efst.hr

SAŽETAK

Izraz "digitalni nomad" odnosi se na skupinu visoko mobilnih pojedinaca neovisnih o lokaciji, a koji koriste digitalnu tehnologiju za obavljanje svog poslovanja na daljinu s bilo kojeg mjesta u svijetu. "Digitalni nomadizam" odnosi se na način života koji su ti nomadi stvorili. Mnoge teorije smatraju digitalni nomadizam rezultatom dinamike radnog mjesta, porastom rada na daljinu te sve većim mogućnostima i zahtjevima radnika za mobilnošću. Sve veći broj ovakve vrste putnika kroz godine je povećao interes privatnih iznajmljivača te raznih vlasnika hotela i hostela da uzmu u obzir ovakvu vrstu turista. Digitalni nomadi traže države s nižim troškovima života od svojih matičnih država, odličnom ponudom prirodnih i kulturnih znamenitosti, solidnim javnim prijevozom, brzim prosječnim Internetom te da je zemlja sigurna. Ove uvjete za digitalne nomade ispunjava Hrvatska, konkretnije, u ovom primjeru, grad Split i njegova okolica. Grad Split ima odličnu i široku ponudu smještaja koji se zadnjih godina prilagođava za ovakvu vrstu putnika. Split je također odlično prometno povezana te njegova zračna luka svake godine dobiva nove partnere i ruši rekorde posjećenosti. Uz analizu sekundarnih podataka, provedeni su dubinski intervjui prvo s digitalnim nomadima da se ispitaju njihova iskustva i mišljenja o gradu Splitu i njezinoj okolici te dubinski intervjui s privatnim iznajmljivačima od kojih želimo ispitati njihova iskustva iznajmljivanja digitalnim nomadima.

KLJUČNE RIJEČI: Digitalni nomadi, Turistički potencijal grada Splita i okolice, Internet i rad na daljinu

DIGITAL NOMADS – RESEARCHING THE POTENTIAL OF THE CITY OF SPLIT AND ITS SURROUNDINGS

ABSTRACT

The term "digital nomad" refers to a group of highly mobile, location-independent individuals who use digital technology to conduct their business remotely from anywhere in the world. "Digital nomadism" refers to the lifestyle these nomads have created. Many theories consider digital nomadism as a result of workplace dynamics, the rise of remote work and the increasing opportunities and demands of workers for mobility. Over the years, the growing number of this type of traveller has increased the interest of private renters and various hotel and hostel owners to consider this type of tourist. Digital nomads look for countries with a lower cost of living than their home countries, an excellent offer of natural and cultural attractions, solid public transportation, fast Internet, and that the country is safe. These conditions for digital nomads are met by Croatia, more specifically, in this example, the city of Split and its surroundings. The city of Split has an excellent and wide range of accommodation that has been adapted for this type of travellers in recent years. Split is also well connected by traffic, and its airport gets new partners every year and breaks records in the number of passengers. Along with the analysis of secondary data, in-depth interviews were conducted, first with digital nomads to examine their experiences and opinions about the city of Split and its surroundings, and in-depth interviews with private renters from whom we want to examine their experiences of renting to digital nomads.

KEYWORDS*:* Digital nomads, Tourist potential of the city of Split and its surroundings, Internet and remote work

1. UVOD

Split je najveći hrvatski grad na istočnoj obali Jadranskog mora i drugi po veličini grad u Republici Hrvatskoj. Split ima prilično dobru klimu tijekom cijele godine, s prosječnom godišnjom temperaturom od 17 stupnjeva Celzijevih i čak 107 vedrih dana (Turizam u brojkama 2020).[1] Upravo je klima jedan od razloga što se zadnjih pet godina u Hrvatskoj javlja novi tip turista, poznatijih kao "digitalni nomadi". „Pojam "digitalni nomad" odnosi se na osobe koje rade na daljinu koristeći tehnologiju i vode mobilni način života umjesto da su fizički prisutni u sjedištu ili uredu tvrtke.[2] Prve naznake digitalnog nomadstva su se pojavile 1997. godine kada je japanski pisac Tsugio Makimoto u knjizi „Digital Nomad“ argumentirao da će nova tehnologija omogućiti ljudima da se vrate u nomadsko stanje i rade s bilo kojeg mjesta na svijetu. Tsugio je u svojoj knjizi i predvidio: “ 21. stoljeće će biti tisućljeće koje će čovječanstvu stvoriti dilemu koja već postoji 10.000 godina kojom će se ljudi zapitati: Jesam li nomad ili doseljenik?“(Makimoto, 1997). Godine 2020. gotovo 11 milijuna Amerikanaca sebe smatra digitalnim nomadima.[3] Danas u svijetu postoji oko 35 milijuna digitalnih nomada raznih nacionalnosti.[4] Ovakav način rada je poznat praktički od nastanka interneta, no jako se popularizirao tijekom zadnjih pet godina, posebice od pandemijske 2020. godine kada nije bilo

[1] https://www.htz.hr/sites/default/files/2021-06/HTZ%20TUB%20HR_%202020_0.pdf
[2] https://www.merriam-webster.com/dictionary/digital%20nomad
[3] https://www.mightynetworks.com/encyclopedia/digital-nomad
[4] https://passport-photo.online/blog/digital-nomad-statistics-and-trends/

druge opcije za raditi nego od doma. Od tada među digitalnim nomadima postoji tendencija za odlazak na turističke destinacije gdje provode po par mjeseci ili čak godina. Jedna od takvih destinacija je i Hrvatska koja, naspram ostalih država odakle dolaze nomadi, ima niži standard življenja i time jeftinije uvjete za življeti. To je slučaj pogotovo van turističke sezone što nadmašuje sva očekivanja digitalnih nomada. Hrvatska danas, a pogotovo grad Split, imaju odličnu priliku privući ovu vrstu putnika/turista, ne samo u sezoni, nego i van turističke sezone. Predmet istraživanja ovog rada je potencijal grada Splita i njegove okolice u dovođenju i popularizaciji ove vrste putnika. Temeljni istraživački ciljevi su sljedeći*: (1) definirati digitalne nomade, čime se bave, koje su im karakteristike te koji su uvjeti potrebni za ulazak digitalnih nomada u Republiku Hrvatsku; (2) u kojoj mjeri je Split atraktivna lokacija za digitalne nomade u smislu kulture, ljudi, ponude smještaja, troškova življenja i dugoročnog življenja u tom mjestu; (3) da li se privatnim iznajmljivačima u Splitu isplati iznajmljivati smještaj digitalnim nomadima kroz čitavu godinu; (4) da li je digitalno nomadstvo budućnost načina rada u turizmu za Split i određene smještajne kapacitete; (5) da li će u budućnosti kompanije diljem svijeta biti primorane mijenjati način rada kako bi zadržale dobre zaposlenike i omogućila im pravo rada na daljinu bilo gdje u svijetu.* Kako bi dobili odgovore na istraživačka pitanja, analiziran je privatni smještaj i smještajni kapaciteti grada Splita i okolice, njihove prosječne mjesečne cijene na platformama poput Airbnba i drugih online platformi vezanih uz iznajmljivanje digitalnim nomadima. Empirijski dio istraživanja obuhvaća dubinski intervju s digitalnim nomadima koji su već jednom boravili u Hrvatskoj te dubinski intervju s privatnim iznajmljivačima iz grada Splita i okolice koji već imaju iskustva iznajmljivanja digitalnim nomadima. Doprinosi ovog istraživanja su teorijski i empirijski. U empirijskom dijelu, metodom dubinskih intervjua saznale su se preferencije digitalnih nomada u odabiru zemalja, vrste smještaja, ponuda itd.. Saznale su se i preferencije od strane iznajmljivača, u i oko grada Splita, na temelju njihovih iskustava s iznajmljivanjem digitalnim nomadima i stavova prema potencijalu ove vrste turizma.

2. DIGITALNI NOMADIZAM

Najčešća stvar u vezi s konceptom digitalnog nomadizma je da su ti ljudi „agnostici lokacije“, koriste tehnologiju za obavljanje svojih poslova i žive nomadskim načinom života. Pisac Steve Roberts, koji je započeo svoju turneju diljem Sjedinjenih Država 1983., bio je možda prvi digitalni nomad. Tijekom svog osmogodišnjeg putovanja, Roberts je svom ležećem biciklu dodavao sve više i više tehnologije, uključujući radio, mobitel, bateriju, računalo i tipkovnicu s četiri tipke sa svake strane upravljača. Roberts i oni koje je poticao sebe su nazivali tehnomadima (Gussekloo, 2016). Digitalni nomadi rade na daljinu, umjesto da su fizički prisutni u sjedištu ili uredima tvrtke. Digitalni nomadski način života omogućen je kroz nekoliko inovacija, uključujući softver za upravljanje sadržajem, jeftin pristup internetu putem Wi-Fi-a, pametnim telefonima i Voice over Internet Protokol-ima (VoIP) za kontaktiranje kupaca i poslodavaca.(Hayes, 2021.) Ako samo odaberemo nekoliko poslova koji se mogu obavljati u uredu i koristiti kao "posao na daljinu", kao što je računovođa, oni su na godišnjoj razini plaćeni u SAD-u 57.000 dolara, podatkovni znanstvenik 97.200 dolara ili inženjeru kibernetičke sigurnosti je prosječna godišnja plaća oko 93.480 dolara (Thompson, 2019). Kada ljudi na takvim poslovima žele živjeti izvan svoje domovine, u ovom slučaju građani SAD-a, najviše ih privlače jeftine, sigurne, egzotične i atraktivne zemlje, od kojih je, srećom po nas, Hrvatska također na radaru digitalnih nomada. Digitalni nomadi pronalaze posao putem raznih internetskih stranica, ali najpopularniji su nesumnjivo LinkedIn, We Work Remote, Flex Jobs i Stack Overflow (Hayes, 2021). Prednosti digitalnog nomadstva su*: fleksibilnost; mogućnost*

putovanja; zajednica i upoznavanje novih pojedinaca; niski troškovi života[5]. Uz prednosti postoje i odredbeni nedostaci kao što su: *čežnja za domom; povećanje osobne potrošnje; nedostatak motivacije; administrativni izazovi*.[6] Ako bi se država ili grad smatrali idealnom lokacijom za digitalne nomade, svako odredište mora biti označeno s nekoliko ključnih stvari. Za to su potrebna kvalitetna Internet veza, relativne niske cijene života u smislu stanovanja, prijevoza i osobnih potrepština, široka dostupnost „coworking" prostora i kafića koji su prilagođeni za prijenosna računala te je važno za digitalnog nomada da u svoje slobodno vrijeme ima na raspolaganju zabavne i zanimljive stvari u regiji u kojoj se nalazi. Naravno, postoje mnogi drugi čimbenici koje treba uzeti u obzir pri odabiru destinacije, kao što su sigurnost, noćni život, vrijeme, zdravstvena zaštita, mogućnost hodanja i bicikliranja itd..[7] Po popisu iz Tablice 1 možemo vidjeti da su ovo lokacije ne nužno neka poslovna središta svijeta, nego su to gradovi i države koje su turistički atraktivne i popularne, s dubokom poviješću te su troškovi života niži od država odakle većina digitalnih nomada i dolazi (izuzev Austina, Melbourne, Barcelone i Berlina).

Tablica 1: Rang lista najpopularnijih gradova za digitalne nomade u 2022. godini.

Rang	Ime grada	Ime države u kojoj se nalazi grad
1.	Lisabon	Portugal
2.	Melbourne	Australija
3.	Chiang Mail	Tajland
4.	Canggu Bali	Indonezija
5.	Ubud Bali	Indonezija
6.	Ho Chi Minh City	Vijetnam
7.	Cape Town	JAR
8.	Budimpešta	Mađarska
9.	Berlin	Njemačka
10.	Barcelona	Španjolska
11.	Las Palmas	Španjolska
12.	Rio de Janeiro	Brazil
13.	Medellin	Kolumbija
14.	Santa Teresa	Costa Rica
15.	Tulum	Meksiko
16.	Austin, Texas	SAD

Izvor: https://bydigitalnomads.com/best-cities-for-digital-nomads

Iako su godine pandemije 2020. i 2021. zasigurno potaknule trend ljudi koji su prisiljeni raditi od kuće i postali "de facto" digitalni nomadi, taj će trend i dalje biti u porastu, samo će se lagano usporavati. (Borges, 2022) Ekonomska vrijednost globalnih digitalnih nomada je otprilike 787. 000. 000. 000 $ godišnje, kao i potencijalni priljev kapitala i ulaganja iz inozemstva te moguća razmjena vještina i zapošljavanje lokalnih radnika. Trenutno je 21 država uspostavila posebne vize za digitalne nomade. Neke od osnovnih karakteristika i statistika su da je postotna razlika u spolovima praktički jednaka (51,49 u korist muškaraca) te da je prosječna dob digitalnog nomada 32 godine. Gotovo 80% digitalnih nomada ostaju u jednoj državi od 3 do 9 mjeseci te su im najveći izazovi pri pronalasku smještaja brzi i pouzdani Internet.[8] Digitalni nomadi će se najviše odlučiti biti u hotelima, ali to je najčešće kratkoročne prirode kada su u tranziciji između zemalja. Dolazak u obitelji ili prijatelja je druga najpopularnija opcija, ali to se najvjerojatnije događa u istoj zemlji odakle dolazi digitalni nomad. Zatim slijede smještaji preko online platformi i hostela koji digitalni nomadi najčešće koriste van svojih matičnih zemalja. Najviše

[5] https://www.entrepreneur.com/article/395465
[6] https://www.masterclass.com/articles/what-is-a-digital-nomad#34SfIhy8ttmMJvnKJQcYYe
[7] https://dollarflightclub.com/digital_nomad_guides/best-cities-for-digital-nomads-to-work-remotely
[8] https://thrivemyway.com/digital-nomad-stats/

se odlučuju za hotele koji mogu biti dosta povoljni za njih ako se radi o zemljama gdje su niski troškovi života (primjerice Tajland i Vijetnam). Prema podacima Airbnba, broj dugoročnih boravaka (minimalno 28 noćenja) gotovo je dvostruko porastao tijekom prvog kvartala 2021. u usporedbi s istim razdobljem prethodne godine. Prelazak na rad na daljinu izazvan pandemijom naučio je tvrtke svih veličina da rad na daljinu funkcionira. Ovo je dovelo do široke potpore rukovoditelja, menadžera i radnika da i dalje dopuštaju fleksibilne rasporede rada i da rade dogovore o radu na daljinu nakon završetka pandemije. Ovaj pomak utječe na trend digitalnih nomada na tri glavna načina: tradicionalniji zaposlenici postat će digitalni nomadi; bliže putovanju kući; duži boravak i manje putovanja (MBO, 2021). S promjenama u kulturi radnog mjesta koje smo doživjeli tijekom 2020. godine, mnoge tvrtke ubiru prednosti distribuirane radne snage. To uključuje, ali nije ograničeno, na povećanu fleksibilnost, smanjene troškove povezane s korištenjem fizičkog ureda i mogućnost zapošljavanja talenata iz veće grupe kandidata (Stumpf et.al., 2022). Pojavu digitalnog nomadizma dodatno je potaknuo sve veći razvoj "društvene tehnologije" (npr. društveni mediji, kao što su Instagram, Twitter, LinkedIn i Facebook). Nastanak Skype-a 2003. godine je pripomogao virtualnoj komunikaciji sa zaposlenicima i predstavlja prvi globalni komunikacijsku platformu s video komunikacijom. Kasnije tijekom desetljeća, "računalstvo u oblaku" pojavilo se kako bi zadovoljio IT potrebe nomada i drugih radnika, osobito s lansiranjem Dropboxa 2007 (Schlagwein, 2018). Posjedovanje "kućnog ureda" postalo je sve više prihvaćeno u raznim industrijama, osobito za djelatnike informacijske i komunikacijske tehnologije (ICT) kao što su programeri. Tijekom 2010-ih „coworking“ prostori postali su sve važniji, njihov se broj otprilike udvostručuje svake godine. Primjerice, broj digitalnih nomada je bio samo milijun u 2017 godini (Foertsch 2017). Paralelno, pojavile su se online zajednice za digitalne nomade kao što su Nomad List, Hashtag Nomads i Dynamite Krug/tropski MBA. Počele su se organizirati konferencije digitalnih nomada, uključujući DNX (od 2014.) i CUAsia (od 2015). Coworking, online zajednice i konferencije oblikovali su, i bili oblikovani njime, nastajući pojam zajedničkog identiteta "digitalnog nomadizma"(Schlagwein, 2017) Mnogi digitalni nomadi su "flashpackeri", kategorija koja je okarakterizirana kao post-backpacker od strane putnika s većim budžetom koji intenzivno koriste tehnologiju, dok, u isto vrijeme, tražeći slične destinacije i stilove života onima koje traže "budget" putnici.

3. UVJETI BORAVKA ZA DIGITALNE NOMADE U HRVATSKOJ I SPLITU

Da bi digitalni nomadi nesmetano boravili u Hrvatskoj te iskorištavali u potpunosti naše prirodne ljepote i povoljne troškove života, moraju ispuniti određene uvjete prije dolaska u zemlju. Zakonom o digitalnim nomadima iz 2021. godine se u potpunosti definirao odnos prema digitalnim nomadima i njihovim vizama za Hrvatsku. Trajanje privremenog boravka je do godinu dana te se ne može produžiti. Zahtjev za reregulaciju prebivališta digitalnog nomada može se podnijeti nakon isteka roka od šest mjeseci od isteka važenja privremenog boravka. Za dokazivanje razloga prisutnosti digitalnog nomada u Republici Hrvatskoj definirana je točna potrebita dokumentacija. Porezno oslobođenje propisano je za primitke koje će digitalni nomad ostvarivati zbog činjenice da je državljanin treće zemlje koji radi ili je zaposlen u obrtu ili vlastitom poduzeću koje nije registrirano u Republici Hrvatskoj i tamo ne obavlja poslove niti pruža usluge poslodavcima, nema status osiguranja kod nadležnih organizacija (HZMO i Hrvatski zavod za zdravstveno osiguranje) temeljem radnog odnosa ili samostalne djelatnosti.[9] Danas postoji i platforma sa svrhom da digitalnim nomadima omogući elektroničko podnošenje zahtjeva za privremeni boravak. Nomadske vize će nedvojbeno postati popularnije u

[9] https://narodne-novine.nn.hr/clanci/sluzbeni/2020_12_133_2520.html

budućnosti[10]. Gospodarstvo neće imati značajnije financijske koristi od toga da Hrvatska svojim pravnim sustavom uredi ovaj način poslovanja, ali će država nedvojbeno imati koristi od promocije svoje destinacije. Hrvatska ima potencijal postati poznata kao poželjna lokacija za digitalne nomade, mameći inteligentne strance da ovdje žive i rade.[11] Kao način olakšavanja digitalnim nomadima prilikom njihovog puta od pronalaska vize i načina kako putovati i što vidjeti u Hrvatskoj, sve do savjeta u biranju smještaja, pomaže i web stranica Hrvatske turističke zajednice namijenjena digitalnim nomadima: „Croatia, your new office!“ Na ovoj stranici nalaze se sve relevantne informacije o registraciji i boravku u Hrvatskoj za digitalne nomade. Digital Nomad Association (DNA) kojem je suosnivač i inicijator hrvatske vize za digitalne nomade, nizozemski poduzetnik Jan de Jong, ima za misiju da DNA Hrvatska treba podržavati i služiti digitalnim nomadima i lokalnim tvrtkama u Hrvatskoj. DNA Hrvatska je neprofitna organizacija s jednim glavnim ciljem, a to je razvoj i promocija Hrvatske kao destinacije digitalnih nomada.[12]

Graf 1: Prikaz broja putnika u Zračnoj luci Split po mjesecima

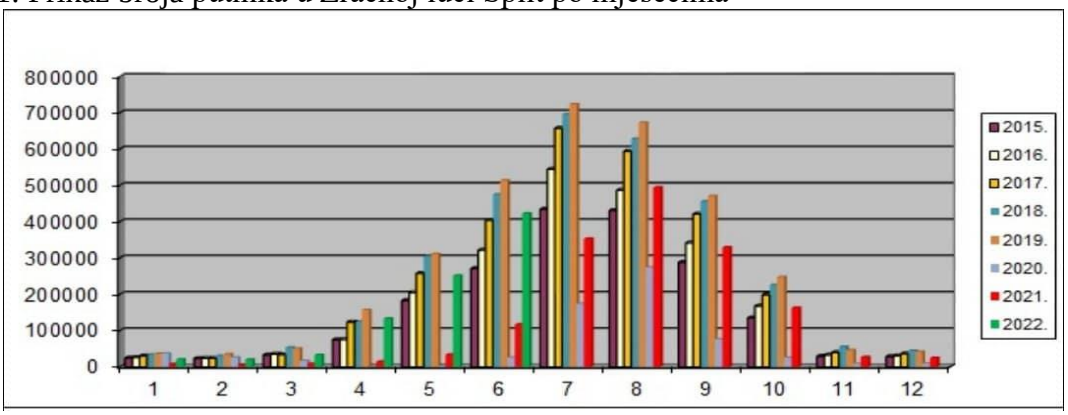

Izvor: http://www.splitairport.hr/index.php?option=com_content&view=article&id=160&Itemid=115&lang=hr

Tablica 2: Troškovi života u gradu Splitu i njezinoj okolici

Troškovi života u Splitu	**Prosječna Cijena**	**Rang**
Restorani		
Obrok, jeftin restoran	60.00 kn	50.00-80.00kn
Obrok za 2 osobe, restoran srednje klase, tri slijeda	250.00 kn	200.00-350.00 kn
Domaće pivo (točeno 0,5 litara)	18.00 kn	15.00-30.00 kn
Cappuccino (običan)	12.44 kn	8.00-15.00 kn
Cola/Pepsi (boca od 0,33 l)	15.00 kn	10.00-18.00 kn
Voda (boca od 0,33 l)	10.39 kn	7.00-15.00 kn
Trgovina		
Mlijeko (obično), (1 litra)	6.75 kn	5.00-8.00 kn
Štruca svježeg bijelog kruha (500g)	7.63 kn	5.00-9.00 kn
Riža (bijela), (1kg)	13.57 kn	8.00-16.00 kn
Jaja (obična) (12)	16.80 kn	13.20-21.60 kn

[10] https://www.iusinfo.hr/aktualno/u-sredistu/45843
[11] https://mup.gov.hr/gradjani-281562/moji-dokumenti-281563/stranci-333/privremeni-boravak-u-svrhu-boravka-digitalnih-nomada/286832)
[12] https://www.dnastay.com/en/information

Pileći fileti (1kg)	57.11 kn	30.00-85.00 kn
Govedina (1 kg) (ili ekvivalentno crveno meso stražnjeg buta)	77.11 kn	52.00-140.00 kn
Jabuke (1 kg)	9.89 kn	6.00-20.00 kn
Banana (1kg)	10.11 kn	9.49-12.00 kn
rajčica (1 kg)	11.88 kn	5.00-15.00 kn
krumpir (1 kg)	5.57 kn	3.00-8.00 kn
Voda (boca od 1,5 litara)	6.11 kn	4.99-8.00 kn
Boca vina (srednje klase)	40.00 kn	30.00-80.00 kn
Domaće pivo (boca od 0,5l)	8.47 kn	7.00-11.00 kn
Uvozno pivo (boca od 0,33 l)	12.36 kn	8.00-18.00 kn
Pakiranje cigareta od 20 komada (Marlboro)	34.00 kn	33.00-34.00 kn
Prijevoz		
Jednosmjerna karta (lokalni prijevoz)	11.00 kn	9.00-15.00 kn
Mjesečna karta (redovna cijena)	290.00 kn	250.00-300.00 kn
Početak taksija (normalna tarifa)	20.00 kn	12.00-30.00 kn
Taxi 1 km (Normalna tarifa)	8.00 kn	6.00-10.00 kn
Benzin (1 litra)	11.58 kn	10.98-13.37 kn
Komunalije (mjesečno)		
Osnovno (Struja, Grijanje, Hlađenje, Voda, Smeće) za stan od 85m2	892.92 kn	600.00-1,400.00 kn
Sport i slobodno vrijeme		
Fitness klub, mjesečna naknada za 1 odraslu osobu	264.29 kn	200.00-300.00 kn
Kino, međunarodno izdanje, 1 sjedalo	40.00 kn	35.00-65.00 kn
Mjesečna najamnina		
Stan (1 spavaća soba) u centru grada	3,414.95 kn	3,000.00-4,500.00 kn
Stan (1 spavaća soba) Izvan centra	2,538.11 kn	2,100.00- 3,000.00 kn

Izvor: NUMBEO, cost of living in Split(2022.), raspoloživo na: https://www.numbeo.com/cost-of-living/in/Split

Ukupan broj stanovnika koji živi u Splitsko-dalmatinskoj županiji je trenutno oko 424,412 stanovnika , od toga samo u gradu Splitu 161,312 stanovnika (DZS, 2022.). Također, među drugim podatcima, ukupan broj privatnih kućanstava u Splitsko-dalmatinskoj županiji je 151,907, dok je broj stambenih jedinica 275,642.(DZS, 2022.) Niz avio prijevoznika i dobra povezanost Splita, također omogućavaju razvoj ove vrste turizma što je vidljivo i na grafikonu 1. U Tablici 2 možemo vidjeti prosječne troškove koje su ljudi ostavljali tijekom svog boravka u Splitu, od cijene restorana, do visine režija.

4. EMPIRIJSKO ISTRAŽIVANJE

4.1. METODOLOŠKI OKVIR ISTRAŽIVANJA

Kako bi se ostvarili ciljevi istraživanja, prvi dio istraživanja obuhvatio je analizu sekundiranih podataka i mogućnosti grada Splita i okolice kao destinacije za digitalne nomade. U drugom dijelu istraživanja provedeno je ispitivanje pomoću dubinskog intervjua. Za potrebe intervjua koristila su se dva oblika pitanja, jedan intervju sastavljen je od 20 pitanja slobodnog oblika te je namijenjen digitalnim nomadima koji su na minimum od mjesec dana boravili u gradu Splitu

ili u njezinoj okolici, te drugi intervju sastavljen je od 14 pitanja slobodnog oblika koji je namijenjen privatnim iznajmljivačima koji imaju višegodišnje iskustvo iznajmljivanja digitalnim nomadima. Postavljeni su sljedeći istraživački ciljevi: (1) Istražiti u kojoj je mjeri Split atraktivna lokacija za digitalne nomade u smislu kulture, ljudi, ponude smještaja, troškova življenja i dugoročnog življenja na području grada Splita i okolice; (2) Istražiti da li se privatnim iznajmljivačima u Splitu isplati iznajmljivati smještaj digitalnim nomadima kroz čitavu godinu; (3) Istražiti da li je digitalno nomadstvo je budućnost načina rada u turizmu; (4) Da li će se u budućnosti dogoditi da jedan dio kompanija diljem svijeta neće moći zadržavati zaposlenike u svojim poslovnim uredima nego će im davati pravo rada bilo gdje u svijetu. Obavljeno je 6 dubinskih intervjua i to 3 sa digitalnim nomadima te 3 sa privatnim iznajmljivačima. Intervju je sniman diktafonom.

4.2. REZULTATI ISTRAŽIVANJA

Oko 50% digitalnih nomada koristi stranicu Airbnb za pronalaženje dugoročnog najma te u slučaju Airbnba to je minimalno 28 dana za smještaj. Uz dubinske intervjue u ovom istraživanju je napravljena i analiza 20 smještaja u Splitu koji su dostupni od 1. studenog 2022. do 30. studenog 2022. Analiza je pokazala da za razliku od drugih platformi gdje se specificira naziv objekta, nazivi nekretnina putem Airbnba ne sadrže uvijek ime samog smještaja jer ova platforma radi sistemom oglasa, te će neke nekretnine kao oglas imati naziv svoje nekretnine: "Prekrasan pogled na more, blizu centra grada). Na temelju ovih 20 objekata, dolazimo do prosječne cijene mjesečnog smještaja u Splitu i okolici od 690 eura (5183 HRK) te prosječne ocjene od 4,83 na Airbnb platformi, što je odličan prikaz splitskih domaćina na njihovom gostoprimstvu te kvaliteti smještaja. Od ostalih platformi koje treba izdvojiti, a koje su na raspolaganju digitalnim nomadima imamo web stranice koje su specifično namijenjene za višemjesečni najam prema digitalnim nomadima i to Trawerk i Dna Stay. *Trawerk* je hrvatska web stranica te se striktno bavi iznajmljivanjem smještaja digitalnim nomadima na minimalni period od jednog mjeseca. U periodu istraživanja u gradu Splitu i njezinoj okolici ovu platformu su koristila 72 najmodavaca te se cijene kreću od 350 eura mjesečno do čak 1500 eura mjesečno. Ovo su cijene koje su pogledane na mjesečnoj razini od 1.11.2022.-1.12.2022. godine u Splitu i okolici. Prosječna cijena objekta je ipak oko 800 eura na tih 72 najmodavaca što pokazuje da ni nakon turističke sezone, cijene nisu nešto niže. Najviše se radi od apartmanima s jednom spavaćom sobom i velikim bračnim krevetom, većinom su jedinice novouređene te garantiraju veliku brzinu interneta i sigurnosti. Iako u te navedene apartmane mogu stati i više od jedne osobe, najčešće 2 do 3, digitalni nomadi se gotovo uvijek kreču solo te su navedene cijene čak i za njih previsoke. *Dna Stay* je osnovao poznati nizozemski poduzetnik Jan de Jong koji je ujedno bio i pokretač inicijative za uvođenje digitalnih viza. U periodu istraživanja, na ovoj platformi se nalazi samo 5 objekta na Splitskom području, što je jako neobično s obzirom da na samoj web stranici tvrde da raspolažu sa oko 15.000 objekata u Hrvatskoj. Slično kao i u Trawerk-u, prosječna cijena je oko 840 eura te je vrsta smještaja isto slična, ali unatoč tome ipak se zaključuje da je cijena dosta visoka uzevši u obzir da digitalni nomadi obično idu sami na svoja putovanja.

Provedeni dubinski intervjui

Empirijski dio istraživanja obuhvaća *dubinski intervju s digitalnim* nomadima koji su već jednom boravili u Hrvatskoj te *dubinski intervju s privatnim iznajmljivačima* iz grada Splita i okolice koji već imaju iskustva iznajmljivanja digitalnim nomadima.

Prva skupina dubinskih intervjua odrađena je s tri digitalna nomada koji dolaze iz sasvim različitih strana svijeta i to s: (1) japanskom softver inženjerkom iz Yokohame koja osam mjeseci putuje kao digitalni nomad, (2) sa švedskim digitalnim nomadom koji trenutno radi kao projekt menadžer u jednoj švedskoj kompaniji te je već dvije i pol godine digitalni nomad; (3) sa softver inženjerom iz SAD-a koji trenutno radi usluge kao freelancer za jednu softversku kompaniju sa sjedištem u poznatoj silicijskoj dolini te zadnje četiri godine radi kao digitalni nomad.

Analizirajući njihove odgovore došlo se do rezultata da u dobroj mjeri svi intervjuirani imaju slična razmišljanja na sva postavljena pitanja. Svo troje ispitanika rade za tvrtke koje im daju djelomičnu slobodu (potrebno je provesti jedan dio vremena u godini u poslovnom uredu kompanije) ili potpunu slobodu rada daljinu. Uglavnom, zbog skupoće smještaja u vrijeme ljetne sezone većina se odlučuje boraviti u Splitu u mjesecima van turističke sezone ili biti jedan dio u sezoni, a ostatak vremena van turističke sezone. U ljetnim mjesecima znaju biti u Zagrebu jer im je grad interesantan za ovakav način rada, a smještaj je jeftiniji nego na moru. Najveća motivacija za postati digitalnim nomadom im je uglavnom sloboda kretanja tijekom radnog odnosa, znači da ne ovise samo o jednom mjestu ili prostoru za rad nego da mogu posjećivati i druge zemlje kao i provoditi dosta vremena sa svojom obitelji. Glavni faktori za biranje Splita su bili ugodna i topla klima (posebice tijekom zimskih mjeseci), sigurna zemlja, kultura ljudi, način na koji ljudi provode dane te općenito stil života kakav ljudi imaju u Dalmaciji, povoljne cijene smještaja i života te brz Internet u smještaju u kojem su se nalazili. Također im je Split bio poželjna lokacija jer je povezan s dosta otoka i mjesta koje također žele posjetiti. Javni prijevoz im je jako bitan te su uglavnom bili zadovoljni gradskim i međugradskim prijevozom iako smatraju da uvijek ima mjesta za napredak. S obzirom da dolaze iz velikih gradova, nije im važno da su u strogom centru grada ako grad ima zadovoljavajući javni prijevoz. U usporedbi s drugim zemljama u kojima su boravili kao digitalni nomadi, Hrvatsku smatraju jako poželjnom zemljom za boravak digitalnih nomada. Svi smatraju da je ovakav način rada jako popularan, posebice u SAD-u, i da će to biti slučaj za sve zemlje. Ovakav trend smatraju odličnom prilikom za ljude koji žele iznajmljivati svoj privatni smještaj ovakvoj vrsti gostiju. Ispitanici smatraju da je ovo definitivno budućnost načina rada u kompanijama te da će, ovisno o vrsti posla, kompanije sve više poticati zaposlenike u ovom smjeru pošto to također znači i uštedu u uredskim troškovima te više zadovoljnih zaposlenika. U konačnici, ispitanici podržavaju hibridni oblik posla (par mjeseci ili tjedana u ureda pa zatim vani) za razliku od čisto „remote“ ili čisto uredskog poslovanja. Također smatraju da su digitalni nomadi najbolji mogući gosti koji neki privatni iznajmljivač može imati jer samo rade za laptopom kada su doma, a kada ih nema u apartmanu, onda idu turistički istraživati. Svi se opet žele vratiti jednog dana u Hrvatsku te savjetuju drugim digitalnim nomadima da obavezno idu u Split, ali ipak van turističke sezone jer većina ipak smatra da je preskupo u to vrijeme boraviti na duže od mjesec dana. U periodu van sezone u kojem su boravili, smještaji u kojima su se digitalni nomad nalazili su imali sve što je potrebno a to je primarno da se nalazi u širem centru grada, da je moderno namješten te da ima brzi Internet. Pri odabiru lokacije i smještaja najvažnija im je brzina interneta, sigurnost zemlje, troškovi života te javni prijevoz u mjestu ili u gradu u kojem se nalaze. Ako smještaj nije u centru grada, već u okolici, onda preferiraju smještaje s pogledam na more s dostupnošću staza za trčanje i biciklizam. Iako znaju za druge manje online platforme koje se fokusiraju na digitalne nomade, svi ispitanici su koristili primarno Airbnb platformu za pronalaženje smještaja te smatraju da je to najbolja i najpouzdanija online platforma za iznajmljivanje.

Druga skupina dubinskih intervjua odrađena je *s tri privatna iznajmljivača* i to s: (1) privatnim iznajmljivačem koji ima iskustva u iznajmljivanju smještaja digitalnim nomadima, smještaj mu

se nalazi u centru grada Splita, točnije u kvartu Varoš, radi se o studio apartmanu od 30 m2 te je namijenjen za 1-2 osobe, tijekom turističke sezone iznajmljuje isključivo kratkoročno, a od početka studenog iznajmljuje dugoročno, iznajmljivač je prije tri godine počeo iznajmljivati digitalnim nomadima nakon što je čuo za njih preko interneta te shvatio priliku za produženjem sezone; (2) privatnim iznajmljivačem iz Splita koji ima višegodišnje iskustvo iznajmljivanja digitalnim nomadima, smještaj koji iznajmljuje se nalazi van centra grada Splita, točnije kvart Trstenik, radi se o novouređenom dvosobnom apartmanu u kojem mogu živjeti do dvije osobe, u zadnje tri godine iznajmljivač iznajmljuje isključivo digitalnim nomadima kroz cijelu godinu najviše zbog toga što je zarada dobra i stalna te nema nikakve brige o gostima ne dnevnoj razini jer iznajmljivač ima i svoj privatni posao pa nema baš vremena se baviti kratkoročnim iznajmljivanjem; (3) privatnim iznajmljivačem u okolici grada Splita, točnije u mjestu Stobreč, radi se o većem broju novouređenih soba s pogledom na more gdje sve jedinice dijele zajedničku kuhinju te prostoriju za rublje, iznajmljivač je počeo nuditi svoj smještaj digitalnim nomadima početkom 2021. godine i to kroz cijelu godinu osim ljetnih mjeseci, točnije od svibnja do kraja rujna nudi isključivo kratkoročni smještaj. S ova tri intervjua su obuhvaćena sasvim tri različita smještaja na tri lokacije čija su obilježja sasvim različita i to: centar grada, kvart van centra grada i okolica Splita.

Do sada iznajmljivači imaju samo pozitivna iskustva te su iznimno zadovoljni ovakvom vrstom gostiju pošto su oni dosta ozbiljniji, visokoškolovani ljudi kojima je cilj raditi te u slobodno vrijeme razgledavati grad i okolicu, ugodni su, mirni i zanimljivi gosti, ne rade buku te samo žele par stvari, a to su mir, dio sobe namijenjen za rad na laptopu te siguran, brz i dostupan Internet. Smatraju da su najvažnije stvari za digitalnog nomada u pogledu smještaja novouređena prostorija, da je u blizini trgovina i autobusne stanice, te da ima brzi pristup internetu. Prihod je dosta veći nego što bi bio da van turističke sezone iznajmljuju studentima ili obiteljima. Za smještaje u okolici Splita koji su više kilometara udaljeni od centra grada, ispitanici smatraju potrebnim da lokacija nudi druge stvari u ponudi te dodaju da su blizina mora, prekrasan pogled te blizina kafića, restorana i trgovina izvrsni preduvjeti za privlačenje digitalnih nomada. Smatraju da je ovo oblik turizma na koji se treba više fokusirati jer se radi o turistima jake platežne moći koji budu više mjeseci na jednom području. Smatraju da je za veće povećanje ove vrsta turizma potrebna izgradnja prometne infrastrukture gdje će fokus biti na izgradnji biciklističkih staza i pješačkih zona čime bi se bolje povezao grad Split s njezinom okolicom. Iznajmljivači također smatraju da ovakav oblik turizma ima jako dobar potencijal u smislu produljivanja turističke sezone, i to ne samo privatnim iznajmljivačima nego i u drugim djelatnostima. Smatraju da država i lokalna samouprava trebaju dodatno prilagoditi zakone i procedure koji će olakšati dolazak ove vrste gostiju te više ulagati u promocijske aktivnosti usmjerene digitalnim nomadima. Iako Airbnb nije jedina platforma s kojom su privatni iznajmljivači upoznati, s njome se isključivo koriste. Većina iznajmljuje na minimalno trideset dana. Dio iznajmljivača je jedno vrijeme koristio i druge online platforme za iznajmljivanje digitalnim nomadima kao što su DNA stay i Trawerk platforme ali smatraju da druge platforme jednostavno nemaju dovoljan broj korisnika i da su cijene na njima previsoke i sasvim nerealne za digitalne nomade. U konačnici svima najviše odgovara način kako upravljaju s Airbnb platformom zbog pouzdanosti i veće baze podataka od drugih manjih platformi.

5. ZAKLJUČAK

Digitalnim nomadima je važno da je zemlja sigurna, da su troškovi života niski i da imaju brz pristup internetu. No, među najvažnijim stvarima je da je zemlja u kojoj odsjedaju atraktivna prirodnim ljepotama, kulturom i načinom života mještana. Hrvatska je odlična destinacija za

ovakvu vrstu putnika/radnika jer je riječ o turistički orijentiranoj zemlji s velikim brojem privatnog smještaja, hostela i hotela u ponudi u kojima digitalni nomadi mogu dobiti visoku kvalitetu boravka. Uvođenjem Zakona o digitalnim nomadima dobivanje vize je jednostavnije, a ona će ujedno omogućiti i nesmetano putovanje po ostalim zemljama članicama EU, kao i manje plaćanje poreza nego što bi to bio slučaj u drugim zemljama da tamo borave kao digitalni nomadi. Ovo istraživanje fokusirano je na grad Split i njegovu okolicu jer pretpostavljamo da ovo područje uz grad Zagreb pruža najbolje uvjete za digitalne nomade u Hrvatskoj. Osim njegovih prirodnih i kulturnih znamenitosti, Split ima privlačan noćni život, prosječno najviše sunčanih dana od svih velikih gradova u RH te je sa svojim dugogodišnjem iskustvom u turizmu već upoznat sa zahtjevima pojedine vrste turista. Iako se preko raznih EU projekata ulaže u omogućavanje lakšeg korištenja alternativnog načina prijevoza, i dalje je trenutni nedostatak Splita slabo razvijena prometna infrastruktura. Primjerice, prometnice ne podupiru prijevoz biciklima i/ili električnim romobilima što sigurno igra faktor digitalnim nomadima pri biranju Splita naspram, primjerice, grada Zagreba. Provedbom dubinskih intervjua s digitalnim nomadima koji su u nekom trenutku boravili u gradu Splitu, rezultati su pokazali da su digitalni nomadi bili iznimno zadovoljni svojim boravkom te su posebno pohvalili ljepotu grada, ostatka Županije i kvalitetu smještaja u kojem su odsjeli. Nedostaci su im javni gradski prijevoz te visoke cijene dugoročnog najma tijekom ljetnih mjeseci. Digitalni nomadi u ovim primjerima odsjedali su u prosjeku oko četiri mjeseca što je odlično za nekoga tko iznajmljuje smještaj izvan turističke sezone jer zbog toga ne mora biti prazan sve do ponovnog početka turističke sezone. Također, dubinski intervju je proveden i s privatnim iznajmljivačima koji imaju iskustva iznajmljivanja smještaja ovakvoj vrsti gostiju. Došlo se je do zaključka da iznajmljivači izrazito preferiraju ovakvu vrstu gostiju, konkretno zbog toga što su to uglavnom visokoobrazovane osobe kojima je potreban novouređen smještaj i kvalitetna internetska veza te im je cilj putovati i raditi. Također, iznimno su zadovoljni sa zaradom te svi ispitanici isključivo koriste Airbnb platformu za oglašavanje svog privatnog smještaja, dok druge platforme ne koriste iako su upoznati s njima. Svi ispitanici se slažu da je ovo budućnost rada na koji će se kompanije morati prilagođavati te da je ovo definitivno trend koji će se sve više proširiti. Svi digitalni nomadi smatraju da će potreba za uredima i poslovnim zgradama biti sve manja. U konačnici, svi istraživački ciljevi su potvrđeni čime dokazujemo da grad Split i njegova okolica imaju odličan potencijal za primitak najvećeg broja digitalnih nomada u tom dijelu Hrvatske, a i Europe. Potvrđuje se da je Split atraktivna lokacija za digitalne nomade u smislu kulture, ljudi, ponude smještaja, troškova življenja i dugoročnog življenja na području grada Splita i okolice. Definitivno se prihvaća teza da će ovakav oblik turizma produljiti turističku sezonu. Iako prihodi neće biti ni približno visoki kao oni za vrijeme turističke sezone, mogli bi biti dovoljni za sasvim održiv tip turizma kroz cijelu godinu. Zaključujemo da sve veći dolazak digitalnih nomada pomaže ne samo privatnim iznajmljivačima nego i svim ostalim djelatnostima, od običnih trgovina pa sve do restorana, najviše zato što su to potrošači velike kupovne moći, tj. dosta veće od prosječnog hrvatskog građanina. Taj će trend uvelike pomoći ugostiteljskim djelatnostima i privatnom smještaju da svoj rad ne fokusiraju samo na ljetne mjesece nego i izvan turističke sezone.

REFERENCE

[1] AllTheRooms analytics (2022.): https://analytics.alltherooms.com/
[2] Backe, Chris (2018.): Becoming a Digital Nomad: Step by step guide to the Digital Nomad lifestyle, Independently published
[3] Borges I., (2022.): Digital Nomads: A Growing Trend in Hospitality in Portugal; Advances in Tourism, Technology and Systems (2022): 549-559

[4] Digital Nomads in Zagreb, (2021.): Your favourite destination to work remotely,(Internet), raspoloživo na: https://digitalnomads.infozagreb.hr/
[5] Digitalnomads.world (2021.): A Digital Nomad Guide to Split, (Internet), raspoloživo na: https://digitalnomads.world/city-guide/split/
[6] DNAstay(2022.): Croatia, your new home: https://www.dnastay.com/en
[7] Dollar flight club, (2022.): Best Cities for Digital Nomads to Work Remotely,(Internet), raspoloživo na: https://dollarflightclub.com/digital_nomad_guides/best-cities-for-digital-nomads-to-work-remotely/
[8] Državni zavod za statistiku,(2021.): Zaposlenost i plaće - Zaposleni - pregled po županijama,(Internet), raspoloživo na: https://podaci.dzs.hr/hr/
[9] Foertsch C.(2017.): More Than One Million People Will Work in Coworking Spaces in 2017 dostupno na https://www.deskmag.com/en/coworking-news/the-complete-2017-coworking-forecast-more-than-one-million-people-work-from-14000-coworking-spaces-s
[10] Grad Split, (2022.): raspoloživo na: https://www.split.hr/
[11] Gussekloo A. (2016.): Digital Nomads - How to Live, Work and Play Around the World, Location-Independent Publishers; 1st edition
[12] Hall, Grant, Sigala, Marianna, Rentschler, Ruth & Boyle, Stephen (2019.): Motivations, mobility and work practices; the conceptual realities of digital nomads, Information And Communication Technologies In Tourism.
[13] Hannonen Olga, (2020.): In search of a digital nomad: defining the phenomenon; Inf Technol Tourism 22, 335–353
[14] Hayes, A. (2021.): Investopedia: Digital Nomad: https://www.investopedia.com/terms/d/digital-nomad.asp
[15] Hrvatska turistička zajednica: https://www.htz.hr/hr
[16] Hrvatska, puna života (2021.): Croatia, your new office!, Internet), raspoloživo na: https://croatia.hr/hr-hr/korisne-informacije/digital-nomads
[17] IUS-INFO, (2021.), (Internet), raspoloživo na: https://www.iusinfo.hr/
[18] Jobted, (2022.): Average Salary in the U.S., (Internet), raspoloživo na: https://www.jobted.com/salary
[19] Lock, Statista, (2022.): Airbnb-statistics & facts,(Internet), raspoloživo na: https://www.statista.com/topics/2273/airbnb/
[20] Makimoto, T., & Manners, D. (1997). Digital nomad. New York: John Wiley & Sons.
[21] MBO partners, (2020.): COVID-19 and the rise of the Digital Nomad dostupno na https://s29814.pcdn.co/wp-content/uploads/2021/05/MBO-Partners-Digital-Nomad-Report-2020.pdf
[22] Ministarstvo turizma Republike Hrvatske (2019.): Turizam u brojkama 2019
[23] Ministarstvo unutarnjih poslova Republike Hrvatske (2021.): www.mup.gov.hr
[24] Narodne novine (2021.): Zakon o strancima
[25] Nomadlist (2022.): Digital nomad guide of Split, (Internet), raspoloživo na: https://nomadlist.com/digital-nomad-guide/split
[26] Passport-photo, (2022.): Digital Nomads 2022. Statistics and trends, (Internet), raspoloživo na: https://passport-photo.online/blog/digital-nomad-statistics-and-trends/
[27] Stumpf T.S., Califf C.B., Lancaster J., (2022.): Becoming a Digital Nomad Entrepreneur: A Process Theory; Proceedings of the 55th Hawaii International Conference on System Sciences
[28] Schlagwein, Daniel, (2018.): The History of Digital Nomadism, Conference: International Workshop on the Changing Nature of Work (CNOW)At: San Francisco

[29] Thompson, B.Y., (2019.): The Digital Nomad Lifestyle: (Remote) Work/Leisure Balance, Privilege, and Constructed Community; International Journal of the Sociology of Leisure (2019) 2:27–42
[30] Todorov, Thrivemyway.com (2022.): 30+ Amazing Digital Nomad Stats, Trends and Facts 2022, (Internet), raspoloživo na https://thrivemyway.com/
[31] Turistička zajednica grada Splita (2022.): https://visitsplit.com/hr/1206/korisne-informacije
[32] Vassev N., (2021.): The Pros and Cons of Working From Anywhere, (Internet), raspoloživo na: https://www.entrepreneur.com/article/395465

Review article / Pregledni rad

PODIZANJE RAZINE INTEROPERABILNOSTI TEMELJNIH REGISTARA O OSOBAMA U RH

DARKO GULIJA
Gulija Consulting and Smart Solutions d.o.o.
Vinogradska cesta 74, 10 000 Zagreb, Hrvatska
Darko.Gulija@gcss.solutions

KORNELIJE RABUZIN
Sveučilište u Zagrebu
Fakultet organizacije i informatike,
Pavlinska 2, 42000 Varaždin, Hrvatska
krabuzin@foi.unizg.hr

LEO MRŠIĆ
Visoko učilište Algebra
Gradišćanska 24, 10000 Zagreb, Hrvatska
Leo.Mrsic@algebra.hr

NIKOLA MODRUŠAN
Središnji državni ured za razvoj digitalnog društva
Ivana Lučića 8, 10000 Zagreb, Hrvatska
nmodrusa@hotmail.com

PETAR GULIJA
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
pgulija21@student.foi.hr

SAŽETAK

Novi europski okvir interoperabilnosti (EIF) daje smjernice javnim upravama kako poboljšati upravljanje interoperabilnosti i unaprijediti end-to-end digitalne usluge. Hrvatska za drugim državama Europske unije najviše zaostaje upravo u interoperabilnosti temeljnih registara. Mapiranjem informacija o podacima registra iz Metaregistra na odgovarajući semantički model omogućila bi se semantička interoperabilnost podataka iz web servisa koje pružaju javni registri.

Trenutno su državne matice organizirane kao točne kopije nekadašnjih papirnatih knjiga. Kao rezultat toga, strukture podataka ne prate osobu i njezine životne događaje te matice sadrže suvišne podatke koji su bili potrebni za naslijeđene papirnate obrasce. Sredstvima EU Technical Support Instrument pokrenut je projekt integracije državnih matica u jedinstveni sustav koji će sadržavati točne i pravodobne podatke o građanima i njihovim životnim situacijama.

U radu opisano je stanje vezano uz temeljne registre, mapiranje podataka javnih registra u nacionalni semantički model, stanje vezano uz državne matice, dane su naznake i smjerovi rješavanja s obzirom na detektirane probleme te je naznačen smjer daljnjih istraživanja.

KLJUČNE RIJEČI: interoperabilnost, državne matice, metaregistar, semantičko modeliranje

1. UVOD

Interoperabilnost se definira kao sposobnost heterogenih sustava da razmjenjuju informacije i pričaju istim jezikom.

Novi europski okvir interoperabilnosti (EIF) [1] daje smjernice, putem niza preporuka, javnim upravama o tome (između ostalog) kako poboljšati upravljanje svojim aktivnostima interoperabilnosti i pojednostaviti procese koji podržavaju end-to-end digitalne usluge. Kako bi aktivnosti interoperabilnosti bile učinkovite, pravovremene i visokokvalitetne, države članice EU-a provode EIF u svojim javnim upravama uvođenjem digitalnih javnih usluga koje se oslanjaju na siguran i slobodan protok podataka, koristeći relevantne standarde koji grade osnovu za veću interoperabilnost.

EIF konceptualni model identificira četiri sloja interoperabilnosti (pravni, organizacijski, semantički i tehnički) plus dva sloja upravljanja. U konceptualnom modelu EIF-a, temeljni registri su kamen temeljac pružanja europskih javnih usluga. EIF definira osnovni registar kao „pouzdani i autoritativni izvor informacija, koji drugi mogu i trebaju digitalno ponovno koristiti, gdje je jedna organizacija ovlaštena i odgovorna za prikupljanje, korištenje, ažuriranje i očuvanje informacija i podataka pohranjenih u registrima ". (Europska komisija, 2017.) Temeljni registri su pouzdani izvori osnovnih informacija o podatkovnim entitetima (osobama, gospodarskim subjektima, prostornim jedinicama, vozilima itd.) te moraju biti ažurni te najviše moguće kvalitete i cjelovitosti. Ova vrsta informacija predstavlja "master podatke" za tijela javne uprave i pružanje europskih javnih usluga.

Europska unija redovito prati razinu zrelosti nacionalnih okvira interoperabilnosti država članica. *Digital Public Administration Factsheets*[1] prikazuje novosti u razvoju javnih uprava 31 Europske države koje su te države ostvarile u tekućoj (2023) godini, kao i glavne fokuse razvoja interoperabilnosti i interoperabilnih javnih usluga u Europskoj uniji.

Slika 1. Primjena EIF konceptualnog modela i prekogranične interoperabilnosti u Hrvatskoj

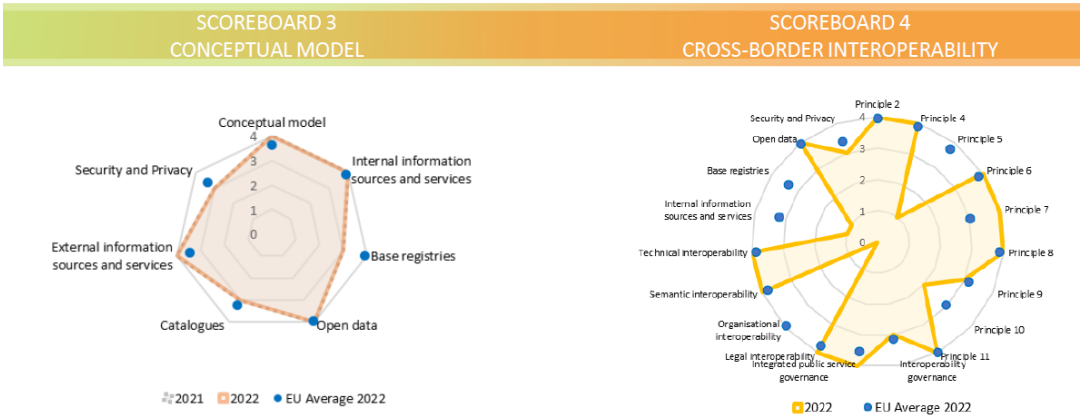

Izvor: NIFO DPA Infographic 2023 Croatia [2]

[1] https://joinup.ec.europa.eu/collection/nifo-national-interoperability-framework-observatory/digital-public-administration-factsheets-2023

Slika 1 pokazuje stupanj primjene temeljnih sastavnica EIF konceptualnog modela i prekogranične interoperabilnosti u Hrvatskoj. Plave točke prikazuju prosječan rezultat u Europskoj uniji, dok narančaste crte prikazuju rezultate za Hrvatsku. Kao što se može primijetiti, Hrvatska najviše zaostaje upravo u interoperabilnosti temeljnih registara.

Zakon o državnoj informacijskoj infrastrukturi [3] definira da je „Temeljni registar javni registar u kojem se prikuplja i vodi barem jedan autentični podatak, a koji je kao temeljni određen odlukom Vlade Republike Hrvatske“.

No, ne postoji odluka Vlade Republike Hrvatske kojom bi se definiralo koji su to temeljni registri, pa slijedom toga ne postoji osnova za primjenu ove odredbe za unaprjeđenje trenutnog stanja, definiranje autentičnih podataka i njihovo preuzimanje iz temeljnog registra umjesto stvaranja redundantnih kopija autentičnog podatka u javnim registrima.

Europski okvir interoperabilnosti EIF [4] kao temeljne registre definira registre koji sadrže podatke o stanovništvu, gospodarskim subjektima, prostoru (adresama) i vozilima.

Temeljem navedenih problema dobivena su EU sredstva za analizu stanja i povećanje razine interoperabilnosti javnih registara. Projekt 21HR28 “Uspostava mehanizma koordinacije za osiguranje koherentnog razvoja e-Uprave“ kao jednu od isporuka definirao je izvještaj o interoperabilnosti javnih registara, temeljem kojeg je napravljen akcijski plan za unaprjeđenje interoperabilnosti javnih registara.

Rad je strukturiran kako slijedi: u drugom poglavlju opisano je stanje vezano uz temeljne registre, a u trećem poglavlju opisano je stanje vezano uz matice, uključujući maticu rođenih, umrlih, vjenčanih i životnih partnerstva. U četvrtom poglavlju dane su naznake i smjerovi rješavanja s obzirom na detektirane probleme, a u petom poglavlju dan je smjer daljnjih istraživanja. Nakon toga slijedi zaključak i literatura.

2. JAVNI REGISTRI

Zakon o državnoj informacijskoj infrastrukturi [3] definira da je svrha temeljnih registara „osigurati dostupnost prikupljenih autentičnih podataka svim tijelima javnog sektora koji su im potrebni za obavljanje poslova iz svog djelokruga“, te određuje da se autentični podaci prikupljaju samo jednom i zapisuju u temeljni registar.

Pojam „Autentični podatak“ definiran je kao „podatak koji je izvoran i vjerodostojan, te je kao takav određen zakonom ili proizlazi iz svrhe uspostave javnog registra određene zakonom.“

Zakon o državnoj informacijskoj infrastrukturi definira i Metaregistar kao registar koji „sadrži osnovne podatke o javnom registru, temelj ustrojavanja javnog registra, oznaku radi li se o temeljnom registru, naznaku vrste podataka koje prikuplja javni registar uz oznaku autentičnosti podataka, mogućnosti dostave podataka i primatelje kojima dostavlja podatke, pravni temelj dostave podataka, opis procesa prikupljanja podataka te pregled načina i uvjeta korištenja podataka.“

Jedna od uloga Metaregistra je i upravljanje servisima nad podacima registra, kao i upravljanje zahtjevima za pristup podacima registra radi uspostave interoperabilnosti – da se izbjegne dugotrajni postupak potpisivanja sporazuma o interoperabilnosti između tijela državne uprave kojima Zakon o državnoj informacijskoj infrastrukturi [3] nalaže da te podatke razmjenjuju.

Prikaz podataka registra u informacijskom sustavu Metaregistra dan je na slici 2:

Slika 2. Prikaz podataka registra u IT sustavu Metaregistra

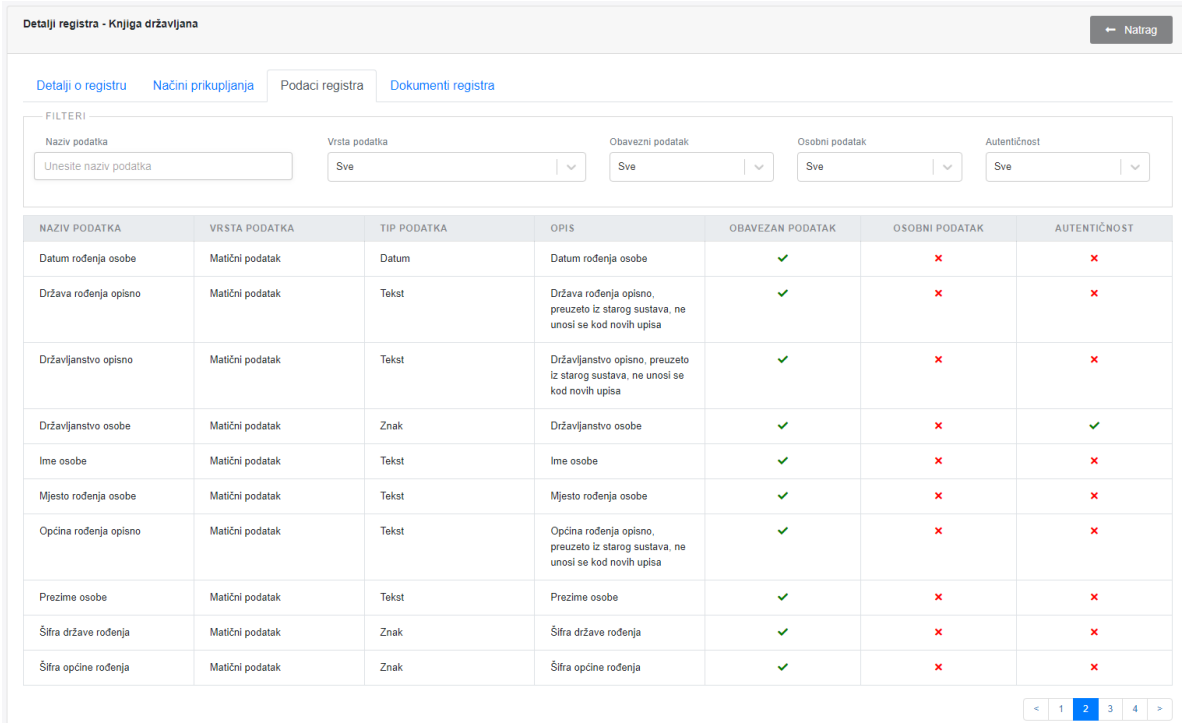

Detalji registra - Knjiga državljana

← Natrag

Detalji o registru | Načini prikupljanja | Podaci registra | Dokumenti registra

FILTERI

Naziv podatka: Unesite naziv podatka

Vrsta podatka: Sve

Obavezni podatak: Sve

Osobni podatak: Sve

Autentičnost: Sve

NAZIV PODATKA	VRSTA PODATKA	TIP PODATKA	OPIS	OBAVEZAN PODATAK	OSOBNI PODATAK	AUTENTIČNOST
Datum rođenja osobe	Matični podatak	Datum	Datum rođenja osobe	✓	×	×
Država rođenja opisno	Matični podatak	Tekst	Država rođenja opisno, preuzeto iz starog sustava, ne unosi se kod novih upisa	✓	×	×
Državljanstvo opisno	Matični podatak	Tekst	Državljanstvo opisno, preuzeto iz starog sustava, ne unosi se kod novih upisa	✓	×	×
Državljanstvo osobe	Matični podatak	Znak	Državljanstvo osobe	✓	×	✓
Ime osobe	Matični podatak	Tekst	Ime osobe	✓	×	×
Mjesto rođenja osobe	Matični podatak	Tekst	Mjesto rođenja osobe	✓	×	×
Općina rođenja opisno	Matični podatak	Tekst	Općina rođenja opisno, preuzeto iz starog sustava, ne unosi se kod novih upisa	✓	×	×
Prezime osobe	Matični podatak	Tekst	Prezime osobe	✓	×	×
Šifra države rođenja	Matični podatak	Znak	Šifra države rođenja	✓	×	×
Šifra općine rođenja	Matični podatak	Znak	Šifra općine rođenja	✓	×	×

< 1 2 3 4 >

Izvor: https://metaregistar.gov.hr/registers/321, dohvaćeno 27.09.2023

Metaregistar za svaki podatak javnog registra omogućava unos ključnih informacijskih atributa:

- Naziv podatka
- Vrsta i tip podatka
- Opis (semantika) podatka
- Je li podatak obavezan ?
- Je li podatak osobni ?
- Je li podataka autentičan ili ne ?

Međutim, struktura Metaregistra na način kako je trenutno implementirana omogućava samo evidentiranje podataka potrebnih za uspostavu interoperabilnosti. Temeljem te evidencije povezivanje registara može se raditi isključivo ručno – dizajnom pojedinačnih rješenja temeljem informacija o podacima koji su sadržani u registrima zapisanim u Metaregistru.

2.1. UN/CEFACT

Centar Ujedinjenih naroda za poticanje trgovine i elektroničko poslovanje (The United Nations Centre for Trade Facilitation and Electronic Business (UN/CEFACT) objavljuje biblioteku jezgrenih komponenti (Core Components Library – UN/CCL) [5].

Trenutna verzija biblioteke, objavljena 03.08.2023, sadrži 625 agregatnih jezgrenih komponenti (ACC) sa 8397 semantičkih pojmova: 5538 osnovnih (BCC) i 2859 asocijativnih (ASCC); te 1390 agregatnih poslovnih informacijskih entiteta (ABIE) sa 13792 semantička pojma: 9048 osnovnih poslovnih entiteta (BBIE) i 4474 asocijativna poslovna entiteta (ASBIE).

Primjer definicije svojstava objekta jezgrene komponente prikazan je na Slici 3:

Slika 3. Prikaz jezgrene komponente

Unique UN Assigned ID	ABIE/ BBIE/ ASBIE/ACC/BCC/ASCC/DT/CC/SC	Dictionary Entry Name (auto generated)	Definition Mandatory	Object Class Term	Property Term	Datatype Qualifier(s)	Representation Term	Associated Object Class	Occurrence Min	Occurrence Max
UN00008106	ACC	Activity. Details	A thing that a person or group does or has done	Activity						
UN00008107	BCC	Activity. Identification. Identifier	An identifier for this activity.	Activity	Identification		Identifier		0	unbounded
UN00008108	BCC	Activity. Type. Code	A code specifying a type of activity.	Activity	Type		Code		0	unbounded
UN00008109	BCC	Activity. Occurrence. Date Time	A date, time, date time or other date time value when this activity occurs or has occurred.	Activity	Occurrence		Date Time		0	unbounded
UN00008110	BCC	Activity. Reason. Code	A code specifying a reason for this activity.	Activity	Reason		Code		0	unbounded
UN00008111	BCC	Activity. Related Activity. Code	A code specifying an activity related to this activity.	Activity	Related Activity		Code		0	unbounded
UN00008112	BCC	Activity. Target. Code	A code specifying a target of this activity.	Activity	Target		Code		0	unbounded
UN00008113	BCC	Activity. Operations. Quantity	A number of operations for this activity.	Activity	Operations		Quantity		0	unbounded
UN00008114	BCC	Activity. Duration. Measure	A measure of a time duration for this activity.	Activity	Duration		Measure		0	unbounded
UN00008115	ASCC	Activity. Specified. Catch	A catch specified for this activity.	Activity	Specified			Catch	0	unbounded
UN00008116	ASCC	Activity. Related. Location	A location related to this activity.	Activity	Related			Location	0	unbounded
UN00008117	ASCC	Activity. Specified. Problem	A problem specified for this activity.	Activity	Specified			Problem	0	unbounded
UN00008118	ASCC	Activity. Specified. Characteristic	A characteristic specified for this activity.	Activity	Specified			Characteristic	0	unbounded
UN00008119	ASCC	Activity. Specified. Gear	Gear specified for this activity.	Activity	Specified			Gear	0	unbounded
UN00008120	ASCC	Activity. Source. Characteristic	A characteristic of the source of this activity.	Activity	Source			Characteristic	0	unbounded
UN00008121	ASCC	Activity. Destination. Characteristic	A characteristic of the destination of this activity.	Activity	Destination			Characteristic	0	unbounded
UN00008122	ASCC	Activity. Related. Activity	An activity related to this activity.	Activity	Related			Activity	0	unbounded
UN00008123	ASCC	Activity. Specified. Document	A document specified for this activity.	Activity	Specified			Document	0	unbounded
UN00008124	ASCC	Activity. Specified. Period	A period specified for this activity.	Activity	Specified			Period	0	unbounded
UN00008125	ASCC	Activity. Specified. Trip	A trip specified for this activity.	Activity	Specified			Trip	0	unbounded
UN00008126	ASCC	Activity. Related. Transport Means	A transport means related to this activity.	Activity	Related			Transport Means	0	unbounded

Izvor: UN/CEFACT Core Components Library 23A, https://unece.org/trade/documents/2023/08/standards/uncefact-ccl-d23a, [5]
U [6] autori opisuju metodologiju za modeliranje poslovnih dokumenata i izgradnju nacionalnog podatkovnog modela temeljem UN/CEFACT Core Components biblioteke.

2.2. EU CORE VOCABULARIES

Umjesto vrlo opširne UN/CEFACT CCL biblioteke, koja nastoji objediniti sva svojstva objekata iz raznih izvora (trgovina, državna uprava), gdje se interoperabilnost postiže redukcijom zajedničkog modela, Europska unija odabrala je donekle različit pristup: EU osnovni rječnici (EU Core Vocabularies) definiraju minimalni standardni zapis osnovnih entiteta [7].

EU Core Vocabularies su pojednostavljeni, iskoristivi i proširivi modeli podataka koji definiraju fundamentalna svojstva ključnih podatkovnih entiteta na kontekstno-neutralan način. Rječnici su namijenjeni standardizaciji razmjene podataka između informatičkih sustava i integraciji raznorodnih podataka iz različitih izvora.

Core Vocabularies definiraju sljedeće rječnike:

- Core Person – definira fundamentalna svojstva osobe, kao što su ime, spol, rođenje;
- Core Business – definira fundamentalna svojstva pravne osobe registrirane u nekom nacionalnom registru (naziv, identifikator, aktivnosti);
- Core Public Organisation – definira fundamentalna svojstva tijela i drugih entiteta javnog sektora;
- Core Location – definira fundamentalna svojstva lokacije, prikazane kao adresa, zemljopisno ime ili lokacija u prostoru;
- Core Criterion and Core Evidence – definira karakteristike koje pravna osoba mora zadovoljiti da bi dokazala sposobnost za npr. sudjelovanje u javnoj nabavi.

EU Core Vocabularies su dostupni u 3 formata zapisa [8]:

- Konceptualni model – model u Excel obliku i statični Unified Moteling Language (UML) model;
- XML schema prema UBL Naming and Design Rules (NDR) konvenciji;
- RDF Schema, povezana s RDF rječnicima kao što su Dublin Core Terms, FOAF, SKOS, itd.

2.3. MAPIRANJE PODATAKA

Mapiranjem informacija o podacima registra iz Metaregistra na odgovarajući semantički model omogućila bi se semantička interoperabilnost podataka iz web servisa koje pružaju javni registri. Mapiranje se može realizirati anotacijom XSD sheme podataka koju registar pruža korisnicima.

Semantički model metapodataka temeljnih registara izrađen je od strane autora ovog teksta u sklopu projekta 21HR28 "Uspostava mehanizma koordinacije za osiguranje koherentnog razvoja e-Uprave". U projektu je izrađen i alat koji omogućava mapiranje modela podataka javnih registara na UN/CEFACT CCL model. Prikaz alata dan je na Slici 4.

Slika 4. Alat za mapiranje podataka registra na UN/CEFACT CCL semantički model

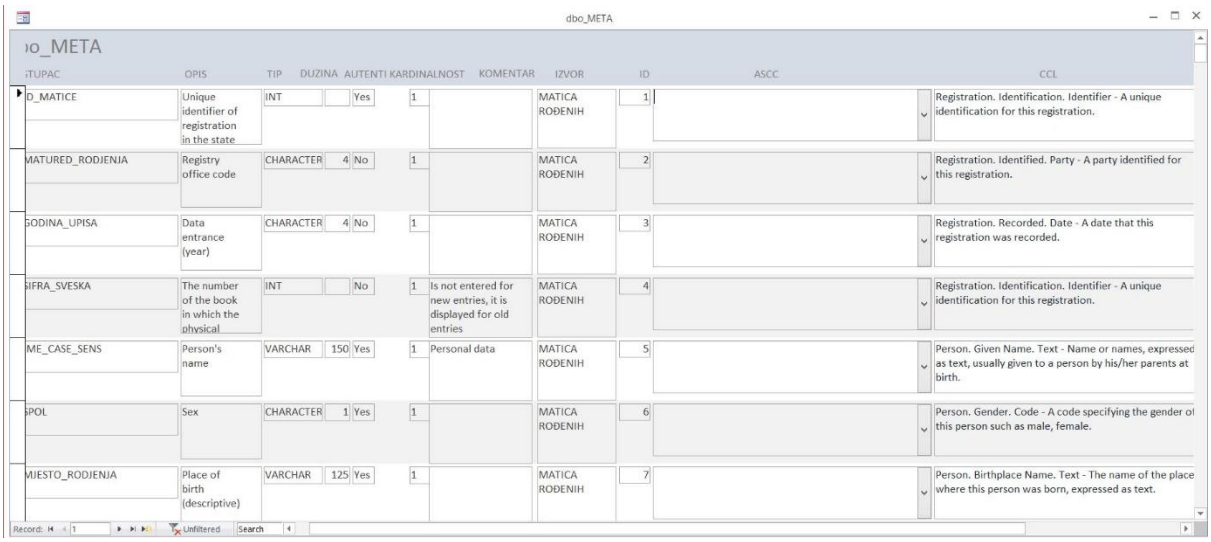

Izvor: Autori

Proširivanje Metaregistra podacima o semantičkom mapiranju podataka registra omogućilo bi da se WSDL sheme servisa generiraju automatski iz strukture podataka samog registra.

3. DRŽAVNE MATICE

U Hrvatskoj autentične podatke o stanovništvu sadrže državne matice: matica rođenih, matica vjenčanih, registar životnog partnerstva, matica umrlih te knjiga državljana.

Na području današnje Hrvatske postoji duga tradicija evidentiranja građanskih stanja građana. Vođenje matičnih knjiga rođenih i vjenčanih u Katoličkoj crkvi propisao je Tridentski sabor (1545.-1563.). U Austro-Ugarskoj su matične knjige još uvijek vodile vjerske zajednice, ali su reformama Josipa II. 1784. postale državne službene knjige. Prema jugoslavenskom Zakonu o državnim matičnim knjigama iz 1946. sve crkvene matične knjige morale su se predati državnim matičarima. Slijedom toga, novi Zakon o izmjenama i dopunama Zakona o državnim matičnim knjigama izdan je u siječnju 1949. i nametnuo je zatvaranje crkvenih matica.

Hrvatski Zakon o matičnim knjigama [9] (NN 96/1993) propisao je upisivanje podataka o rođenju, vjenčanju i smrti. Matične knjige su se vodile u paru, izvornik je bio u papirnatom

obliku, dok se drugi primjerak mogao voditi automatskom obradom podataka uz odobrenje Ministarstva uprave. No samo je Grad Zagreb imao informatički sustav za tu namjenu.

Republika Hrvatska je 2000. godine dobila lokalno informatičko rješenje za svaki matični ured za informacijski sustav za evidentiranje podataka o građanskom stanju. Matični službenici su morali unositi/kopirati podatke iz papirnatih matičnih knjiga (knjiga građanskog stanja) u informatičke sustave i podaci su evidentirani u istoj strukturi kako je propisano za papirnate knjige. To znači da su neki podaci bilježeni više puta (u različitim upisnicima/knjigama), kao i da su neki životni događaji bilježeni kao nestrukturirane tekstualne bilješke.

Zakonom o izmjenama i dopunama Zakona o matičnim knjigama [10] (NN 76/2013) nadležnost za matične knjige predana je hrvatskim županijama, te je propisano da se matične knjige vode u elektroničkom obliku. Svi podaci o građanskom stanju iz lokalnih informatičkih sustava, uključujući i podatke Grada Zagreba, objedinjeni su u jedan informatički sustav na nacionalnoj razini kojim upravlja APIS IT doo. Također, uvedena su dodatna polja za usvajanje, promjenu spola i neke druge slučajeve, što je zaustavilo stvaranje tekstualnih bilješki. Obrasci uvjerenja propisani su Pravilnikom o obrascu matične knjige vjenčanih, izvoda i potvrda koje se izdaju na temelju matičnih knjiga (NN 91/2013).

Trenutno su državne matice organizirane kao točne kopije nekadašnjih papirnatih knjiga. Kao rezultat toga, strukture podataka ne prate osobu i njezine životne događaje onako kako bi trebale, te matice sadrže suvišne podatke koji su bili potrebni za naslijeđene papirnate obrasce.

Sljedeći problem je teritorijalna nadležnost, gdje ovlast za upis podataka u jedan registar (maticu) ne uključuje ovlast za upis povezanih podataka u sve registre. Npr. ako osoba sklopi brak izvan mjesta prebivališta, matičar nadležan prema mjestu sklapanja braka unijet će upis u maticu vjenčanih, ali neće imati ovlast za upis činjenice da osoba više nije samac u maticu rođenih. Podatak o sklopljenom braku slati će u papirnatom obliku nadležnom matičaru, što može dovesti do pogrešaka i dodatnog administrativnog opterećenja.

U [11] analizirana je semantička interoperabilnost javnih registara u Hrvatskoj. Analiza definira mapiranje temeljnih registara na EU Core Vocabularies i UN/CEFACT CCL semantičke modele.

Usporedba korištenja semantičkih svojstava osobe u pojedinim državnim maticama prikazana je u Tablici 1.

Vidimo da podaci potvrđuju probleme detektirane u uvodu poglavlja. Matice sadrže podatke koji nisu autentični, suprotno zakonskoj definiciji, pa se podaci kao što su npr. ime i prezime osobe, prebivalište i datum rođenja, pohranjuju više puta u spomenutim maticama.

Na primjer, podaci o roditeljima osobe sadržani su u maticama rođenih, maticama vjenčanih i maticama umrlih. Matična knjiga rođenih sadrži podatke o prebivalištu roditelja (kao tekst); Matična knjiga umrlih sadrži OIB bračnog druga umrle osobe i prebivalište i sl.

Nadalje, podaci o adresi u matičnim knjigama pohranjeni su kao tekstualni zapisi i nisu povezani s Registrom prostornih jedinica (koji obrađuje promjene naziva ulica) niti s MUP-ovim registrima prebivališta i osobnih dokumenata. Županijski uredi i Grad Zagreb podacima o prebivalištu i boravištu pristupaju ručno putem web aplikacije MUP-a.

Tablica 1. Korištenje svojstava osobe u državnim maticama

Object Class Term	Property Term	Naziv registra			
		Matica rođenih	Matica umrlih	Registar životnog partnerstva	Matica vjenčanih
Person	Birth	4	1	2	2
	Birth Country	3	1	1	1
	Birth Jurisdiction Country Sub-Division		1		1
	Birthplace Name	3	1	1	1
	Death		2		
	Description	1			
	Ethnicity	3	1		1
	Family Name	4	4	4	3
	Gender	1	1	1	1
	Given Name	1			
	Identification	6	3	2	2
	Information Restriction Reason	2		1	1
	Language			1	1
	Maiden Name	1	2		2
	Marital Status		1		
	Name	2	4	7	6
	Residence Country		1		

Izvor: Autori

Elektronički servisi koje pružaju državne matice su kopije starih papirnatih obrazaca. Na taj način višestruke usluge pružaju istovjetne informacije, npr. o prebivalištu osobe – iako taj podatak nije mjerodavan ni u jednoj od njih. Isto je i s promjenama imena, gdje različiti servisi iz matičnih knjiga mogu dati različite podatke o istoj osobi. Registar OIB-a i njegove usluge donekle kompenziraju tu slabost, ali pod cijenu fizičkog kopiranja podataka matičnih knjiga u registar OIB-a, a registar OIB-a nije autentičan izvor za te informacije.

Tijekom procesa digitalizacije papirnatih knjiga o građanskom statusu neki odnosi roditelj/dijete nisu kodirani, već su (sve bilješke prije 2013.) uneseni kao tekstualne bilješke, tako da zapis o djetetu u matičnoj knjizi ima bilješku slobodnog teksta koja nije pretvorena u strukturirani strojno čitljiv sadržaj. Takav zapis generira grešku pristupa servisu Roditelj/dijete – a postoje brojne e-Usluge koje se oslanjaju na servis roditelje/dijete. Naime, servis ne može raditi sve dok na zapisima postoje stare tekstualne bilješke, jer ne zna što ta bilješka sadrži, budući da bi podaci u bilješci mogli biti osjetljivi podaci (npr. o roditeljima posvojenog djeteta).

4. NOVI PROJEKT – SANIRANJE STANJA U MATICAMA

Semantičko modeliranje podrazumijeva mapiranje podatkovnih točaka u klase koncepata koje pružaju strukturu u koju se informacije mogu dodati i povezati s tumačenjem stvarnog svijeta o tome kako se podaci koriste/će se koristiti. Takva se struktura naziva semantičkim modelom podataka. To bi značilo mapiranje svakog pojedinačnog podatkovnog modela registra sve do podatkovne točke, u odnosu na biblioteku temeljnih komponenti kako bi se identificirale glavne objektne klase (grupe) podatkovnih stavki i temeljnih poslovnih informacijskih entiteta.

Identifikacija jedinstvenog relevantnog izvora za svaku podatkovnu točku koju pružaju registri i identificiranje podatkovnih točaka koje se označavaju kao autentične (koji će se koristiti kao univerzalni izvor za buduće potrebe) i redundantne (koji će se sinkronizirati iz mjerodavnih izvora) za svaku sadržanu podatkovnu točku u postojećim registrima osigurati će da registri pružaju usluge koje se odnose na točne i ažurne podatke iz mjerodavnih izvora. Za one registre koji također nude redundantne podatke, trebala bi postojati jasna politika sinkronizacije podržana razlikom između autentičnih i redundantnih podataka.

Temeljem analiza i rezultata već spomenutog projekta 21HR28 "Uspostava mehanizma koordinacije za osiguranje koherentnog razvoja e-Uprave", Republika Hrvatska je zatražila podršku iz EU temeljem EU Uredbe 2021/240 o ustanovljavanju Technical Support Instrument programa za redizajn državnih matica. Cilj projekta je integracija državnih matica u jedinstveni sustav koji će sadržavati točne i pravodobne podatke o građanima i njihovim životnim situacijama (rođenju, državljanstvu, vjenčanju/sklapanju životnog partnerstva i smrti)

Predviđeni rezultat je da jedna osoba bude predstavljena kao jedan entitet, s jedinstvenim identifikatorom za taj entitet i vezama na sve pridružene članove obitelji. Svi statusni podaci bit će samo jednom upisani kao atributi subjekta u jedan registar.

Projekt će uključivati redizajn matičnih knjiga i integraciju postojećih 5 matičnih knjiga u jednu, redizajn poslovnih procesa i programskih rješenja, uključujući postojeće e-usluge koje izravno proizlaze iz matičnih knjiga. Sastavni dio projekta su i primjena naprednih tehnoloških rješenja u matičnim knjigama i korištenje naprednih tehnoloških rješenja za transformaciju podataka matičnih knjiga.

Ovaj registar omogućit će svim građanima da na što jednostavniji način riješe svoj građanski status i status djece. Sve tekstualne bilješke bit će pretvorene u strukturirane podatke i dodane kao atributi primjenom naprednih tehnologija kao što su strojno učenje i umjetna inteligencija (AI).

Ovaj jedinstveni registar predstavljat će temelj za stvaranje e-usluga koje se mogu pružati bez ljudske intervencije i uz pravnu sigurnost u svim sektorima u Hrvatskoj sektora. Jasni i čisti

podaci temeljeni na principu ***samo jednom*** unaprijedit će povjerenje u okruženje javnog sektora, a primjena naprednih tehnoloških rješenja olakšati poslovanje svim korisnicima.

Slika 5. Vrijednosni ciklus podataka

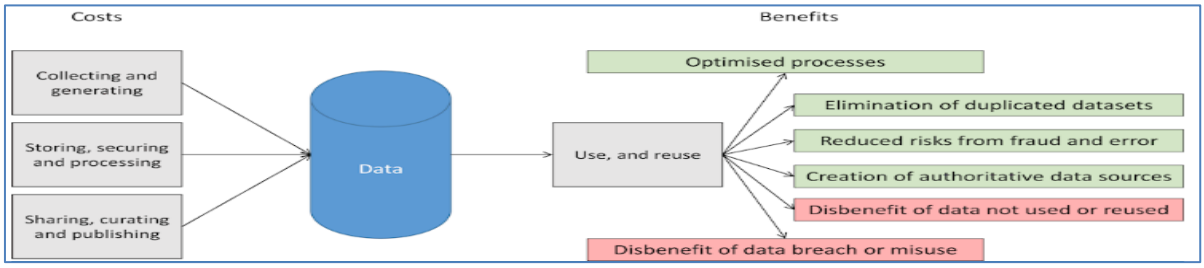

Izvor: The Path to Becoming a Data-Driven Public Sector, OECD [12]

5. DALJNJA ISTRAŽIVANJA

Što se podizanja razine interoperabilnosti u RH tiče, EU Joinup portal sadrži 3 metodologije uključujući online upitnike za procjenu zrelosti interoperabilnosti javnih usluga:

- Interoperability Maturity Assessment of a Public Service (IMAPS) [13];
- Skup alata za brzu procjenu interoperabilnosti upravljanja (GIQAT) [14];
- Structural Interoperability Quick Assessment Toolkit (SIQUAT) [15].

Potrebno je definirati optimalne komponente nacionalnog okvira interoperabilnosti i predložiti integrirani model mjerenja zrelosti interoperabilnosti, uključujući alat za samoprocjenu.

Nadalje, potrebno je posvetiti pozornost procesima i politikama potrebnim kako bi se osiguralo da su podaci korišteni u interoperabilnim javnim uslugama točni i autentični, te implementirati visoku razinu integracije kataloga metapodataka koji sadrži nacionalni semantički model podataka s infrastrukturom za razmjenu podataka. Isto tako, valja istražiti kako spomenuto djeluje kao temelj/aktivator za razvoj usluga koje automatski stvaraju shemu za razmjenu podataka na temelju ograničenja privatnosti i omogućuju korištenje autentične podatke iz mjerodavnih izvora.

Na kraju, potrebno je izraditi i izmjeriti učinke alata za automatsko generiranje web servisa, kako bi se osigurala primjena načela ***samo-jednom (once-only)*** te osiguralo da usluge državne uprave koriste samo podatke koji su autentični i za kojima postoji potreba u pojedinom procesu (načelo razmjernosti).

6. ZAKLJUČAK

Premda Zakon o državnoj informacijskoj infrastrukturi definira da je svrha temeljnih registara prikupljanje autentičnih podataka i osiguravanje njihove dostupnosti svim tijelima javnog sektora, vidljivo je da državne matice ne ostvaruju u potpunosti tu zadaću. Podaci koje sadrže su redundantni i organizirani su kao doslovne kopije papirnatih knjiga iz kojih su digitalizirani, a ne s ciljem dijeljenja autentičnih podataka radi korištenja u tijelima javnog sektora.

Kao posljedicu nedostatka interoperabilnosti među javnim registrima, elektroničke usluge ne primjenjuju princip ***samo jednom (once-only)***, već zahtijevaju od građana i gospodarskih

subjekata da im ponovno dostavljaju podatke koje je državna uprava već prikupila i pohranila u javnim registrima. Time povećavaju administrativno opterećenje što negativno utječe na konkurentnost poslovanja i kvalitetu usluga pruženih građanima. Nadalje, uslijed pohrane i korištenja redundantnih podataka, postoji rizik da podaci na kojima su temeljene javne usluge nisu ažurni ili čak nisu točni.

Radi unaprijeđena interoperabilnosti javnih registara potrebna je izrada i formalizacija nacionalnog okvira interoperabilnosti e-uprave (e-GIF) kako bi se bolje podržalo upravljanje interoperabilnošću vladinih e-usluga. Predloženi nacionalni okvir interoperabilnosti e-uprave (e-GIF) bio bi integriran skupom osnovnih komponenti i popraćen odgovarajućim modelom upravljanja i alatima za objavljivanje i upravljanje njegovim komponentama.

Za poticanje upravljanja i objavljivanja komponenti nacionalnog okvira interoperabilnosti e-uprave i osiguranje njegove koherentnosti, stalnog ažuriranja i relevantnosti potrebno je definirati softversku platformu za upravljanje Nacionalnim okvirom interoperabilnosti. Komponente Metaregistara (npr. katalog standarda, katalog usluga i semantički podatkovni model javnih registara), definirane u ZODII-u, daju solidnu polaznu točku za poboljšanja u kratkom roku. Stvaranje komponenti poput kataloga standarda, semantičkog podatkovnog modela kataloga javnih registara, semantičkog kataloga pravnih pojmova, kataloga osnovnog registra i kataloga usluga može pomoći u rasvjetljavanju semantičkih pojmova i njihove povezanosti s pravnim izvorima, te može razjasniti pojmove i zajedničke definicije i poticati prekogranično korištenje javnih usluga.

U Zakonu o digitalnoj informacijskoj infrastrukturi (ZODII) potrebno je stvoriti preduvjete za ugradnju standarda iz e-GIF kataloga u postupke javne nabave radi poticanja nabave interoperabilnih IT rješenja. Također se preporučuje stvaranje tržišta unaprijed odobrenih i certificiranih IT rješenja kako bi se pojednostavila nabava IT rješenja uz istovremeno osiguranje poštivanja središnjih standarda interoperabilnosti.

Potrebno je osigurati digitalno očuvanje i stalni pristup podacima. S obzirom na važnost podataka pohranjenih u javnim registrima, od ključne je važnosti da ti podaci budu sigurni, sigurni i visoko dostupni. Temeljni registri i registri važni za interoperabilnost trebali bi se smjestiti u podatkovni centar koji ima preporučeni skup zahtjeva za redundancijom i dostupnošću (minimalno TIER 3 podatkovni centar kao što je Centar dijeljenih usluga).
Kad god je to moguće, podatke iz registara treba objaviti u otvorenim formatima (otvoreni podaci). U skladu s najboljom međunarodnom praksom, preporukama Europskog okvira interoperabilnosti (EIF) i načelima OECD-a, otvoreni podaci trebaju biti objavljeni na nacionalnom portalu otvorenih podataka pravodobno, u strojno čitljivim formatima s odgovarajućim metapodacima, te uključivati opis njihovog sadržaja i licenčnih uvjeta pod kojima su dostupni.

REFERENCE

[1] European Commission, „European Interoperability Framework - Implementation Strategy, COM(2017) 134 final, Annex 2“, *COMMUNICATION FROM THE COMMISSION TO THE EUROPEAN PARLIAMENT, THE COUNCIL, THE EUROPEAN ECONOMIC AND SOCIAL COMMITTEE AND THE COMMITTEE OF THE REGIONS*. 2017. [Na internetu]. Dostupno na: https://eur-lex.europa.eu/legal-content/EN/ALL/?uri=COM:2017:134:FIN

[2] „NIFO_DPA_Infographic_2023_Croatia_vFINAL“.
[3] Hrvatski Sabor, *Zakon o državnoj informacijskoj infrastrukturi*. Hrvatski sabor, 2014. Pristupljeno: 27. rujan 2023. [Na internetu]. Dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/2014_07_92_1840.html
[4] European Union, „The New European Interoperability Framework“. 2017. doi: doi:10.2799/78681.
[5] UN/CEFACT, „UN/CEFACT Core Components Library (CCL)“, UN/CEFACT Core Components Library (CCL). Pristupljeno: 29. rujan 2023. [Na internetu]. Dostupno na: https://unece.org/trade/uncefact/unccl
[6] Y. Charalabidis, F. Lampathaki, i D. Askounis, „Unified Data Modelling and Document Standardization Using Core Components Technical Specification for Electronic Government Applications“, *Journal of Theoretical and Applied Electronic Commerce Research*, sv. 3, izd. 3, str. 38–51, 2008, doi: 10.4067/S0718-18762008000200004.
[7] European Commission, „Semantic Interoperability Community (SEMIC) - Core Vocabularies“. [Na internetu]. Dostupno na: https://joinup.ec.europa.eu/collection/semantic-interoperability-community-semic/core-vocabularies
[8] European Union, „e-Government Core Vocabularies handbook Using horizontal data standards for promoting interoperability“, 2015. doi: 10.2799/945287.
[9] Hrvatski Sabor, *Zakon o državnim maticama*. Hrvatski Sabor, 1993. Pristupljeno: 01. listopad 2023. [Na internetu]. Dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/1993_10_96_1878.html
[10] Hrvatski Sabor, *Zakon o izmjenama i dopunama Zakona o matičnim knjigama*. Hrvatski Sabor, 2013. Pristupljeno: 01. listopad 2023. [Na internetu]. Dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/2013_06_76_1525.html
[11] K. Rabuzin, D. Gulija, L. Mršić, i N. Modrušan, „Towards Semantic Interoperability of Core Registers in Croatia“, u *DATA*, 2022, str. 337–344. [Na internetu]. Dostupno na: https://joinup.ec.europa.eu/collection/nifo-national-
[12] OECD Library, „The Path to Becoming a Data-Driven Public Sector“, *OECD Library*. 2019. [Na internetu]. Dostupno na: https://www.oecd-ilibrary.org/sites/059814a7-en/index.html?itemId=/content/publication/059814a7-en&_csp_=a527a7269ce984d41531dc563087a73c&itemIGO=oecd&itemContentType=book
[13] „Interoperability Maturity Assessment of a Public Service (IMAPS)“, Joinup. Pristupljeno: 16. rujan 2023. [Na internetu]. Dostupno na: https://joinup.ec.europa.eu/collection/interoperability-maturity-tools-imts-digital-public-services/solution/imaps/release/v220
[14] „Governance Interoperability Quick Assessment Toolkit GIQAT“, Joinup. Pristupljeno: 16. rujan 2023. [Na internetu]. Dostupno na: https://joinup.ec.europa.eu/collection/interoperability-maturity-tools-imts-digital-public-services/solution/giqat
[15] „Structural Interoperability Quick Assessment Toolkit SIQAT“, *Joinup*, Pristupljeno: 16. rujan 2023. [Na internetu]. Dostupno na: https://joinup.ec.europa.eu/collection/interoperability-maturity-tools-imts-digital-public-services/solution/siqat

Review article / Pregledni rad

DRUŠTVENO ODGOVORNO POSLOVANJE U BANKARSKOM SEKTORU NA PODRUČJU REPUBLIKE HRVATSKE

NIKOLINA ŽUPANIĆ
Fakultet organizacije i informatike
Sveučilište u Zagrebu
Pavlinska 2, 42000 Varaždin, Hrvatska
nzupanic@student.foi.hr

MARINA KLAČMER ČALOPA
Fakultet organizacije i informatike
Sveučilište u Zagrebu
Pavlinska 2, 42000 Varaždin, Hrvatska
marina.klacmer@foi.hr

IVANA ĐUNĐEK KOKOTEC
Fakultet organizacije i informatike
Sveučilište u Zagrebu
Pavlinska 2, 42000 Varaždin, Hrvatska
idjundjek@foi.unizg.hr

SAŽETAK

Društveno odgovorne banke kao financijske institucije nastale su kako bi odgovorile na specifične potrebe društva koje tradicionalni bankovni sektor nije uspio zadovoljiti. Za uspješno društveno odgovorno poslovanje u bankarskom sektoru nužno je model poslovanja temeljiti na transparentnom poslovanju, uspostavi dugoročnih i personaliziranih odnosa s klijentima, DOP uvrstiti u strategiju poslovanja, objavljivati izvješća o društveno odgovornom poslovanju, imati podršku iz unutarnjeg i vanjskog okruženja za provođenje praksi DOP-a. Društvena odgovornost može se prikazati i kroz usluge koje banka nudi, primjerice zeleni krediti, mikrofinanciranje, krediti za obrazovanje, istraživanja, kulturu i umjetnost, krediti za poticanje razvoja obrtništva. Takva politika poslovanja stvora pozitivan publicitet u zajednici u kojoj banke djeluju, može potaknuti lokalni, nacionalni i prekogranični gospodarski učinak, doprinijeti društvenom razvoju uz istovremeno povećanje profitabilnosti banaka, povećava osviještenost o ulozi banaka u društvu te ima pozitivan utjecaj na motivaciju zaposlenika. S obzirom na utvrđenu važnost društveno odgovornog poslovanja u kontekstu bankarskog sektora, cilj ovog rada je analizirati primjenu DOP-a u bankarskom sektoru prema aktivnostima koje se ocjenjuju u upitniku Hrvatskog indeksa održivosti odnosno utvrditi koliko banke na području Republike Hrvatske posvećuju pozornosti društveno odgovornom poslovanju.

KLJUČNE RIJEČI: društveno odgovorno poslovanje, bankarski sektor, Hrvatski indeks održivosti

SOCIAL RESPONSIBILITY IN THE BANKING SECTOR IN THE REPUBLIC OF CROATIA

ABSTRACT

Socially responsible banks as financial institutions were created to respond to the specific needs of society that the traditional banking sector failed to satisfy. For a successful socially responsible business in the banking sector, it is necessary to base the business model on transparent business, establish long-term and personalized relationships with clients, include CSR in the business strategy, publish reports on socially responsible business, have support from the internal and external environment for the implementation of CSR practices. And. Social responsibility can also be shown through the services offered by the bank, for example, green loans, microfinancing, loans for education, research, culture and art, and loans to encourage the development of crafts. Such a business policy creates positive publicity in the community where banks operate, can stimulate local, national and cross-border economic performance, contribute to social development while simultaneously increasing banks' profitability, increase awareness of the role of banks in society, and positively impact employee motivation. Given the established importance of socially responsible business in the context of the banking sector, the aim of this paper is to analyse the application of CSR in the banking sector according to the activities evaluated in the Croatian Sustainability Index questionnaire, that is, to determine how much attention banks in the Republic of Croatia pay to socially responsible business.

KEYWORDS: socially responsible business, banking sector, Croatian sustainability index

1. UVOD

Stjecanje konkurentske prednosti, izgradnja ugleda na tržištu, privlačenje i zadržavanje kvalitetnih zaposlenika, postizanje poslovnog uspjeha te povećanje profitabilnosti samo su neki od ciljeva koje svaka poslovna organizacija nastoji postići. No, ostvarivanje ovih ciljeva zahtijeva ne samo poslovnu izvrsnost, već i primjenu koncepta društveno odgovornog poslovanja. U današnjem okruženju, ravnoteža između ekonomske, ekološke i društvene dimenzije postala je ključna za opstanak poduzeća. Uz sve veću osviještenost društva o ekološkim i socijalnim izazovima, organizacije se suočavaju s pritiskom da doprinesu rješavanju ovih problema te da preuzmu odgovornost za svoj utjecaj. Društvena odgovornost ne samo da podupire zajednicu i održivost, već promiče i temeljne moralne vrijednosti te potiče pozitivan utjecaj na svijet oko nas. Banke potiču ekonomski rast kroz stvaranje novih radnih mjesta i financiranje različitih poslovnih aktivnosti. Također, upravljaju rizicima, olakšavaju novčane transakcije te omogućuju građanima da štede novac na siguran način i podržavaju financijski sustav. Također, pružaju pristup financijskim sredstvima marginaliziranim skupinama, pridonoseći time većoj inkluzivnosti. Aktivno sudjelovanje banaka u društveno odgovornim praksama ima pozitivan i dalekosežan utjecaj na društvo i okoliš. Stoga je nužno da banke prepoznaju svoju ulogu i da društvena odgovornost postane ključna komponenta njihova poslovanja. U ovom radu naglasak je na implementaciji koncepta društveno odgovornog poslovanja u bankarskom sektoru RH. Na temelju sveobuhvatne analize, zaključak rada donosi uvid u stanje društveno odgovornog poslovanja u bankarskom sektoru Republike Hrvatske.

2. DRUŠTVENO ODGOVORNO BANKARSTVO

Globalna financijska kriza istaknula je potrebu za revizijom postojećih strategija i procesa ulaganja u financijskom sektoru, što je rezultiralo razvojem koncepta društveno odgovornog financijskog ulaganja [Ivanišević Hernaus, 2016]. Steurer, Margula i Martinuzzi [2008] navode kako se društveno odgovorna financijska ulaganja odnose na primjenu načela društveno odgovornog poslovanja i održivog razvoja prilikom donošenja odluka o financijskim ulaganjima. Društveno odgovorna financijska ulaganja razlikuju se od tradicionalnih financijskih ulaganja. Tradicionalna financijska ulaganja odnose se na ulaganja u imovinu kao što su vrijednosnice, umjetnine s ciljem ostvarivanja financijskih prinosa. Društveno odgovorna ulaganja su ulaganja individualnih ili institucionalnih ulagača u društveno odgovorna poduzeća ili investicijske fondove te je svrha ovakvog oblika ulaganja ostvariti financijske i nefinancijske ciljeve koji su povezani s društvenim, ekološkim i etičkim čimbenicima društvene odgovornosti. Kod ovakvog oblika ulaganja, ulagači imaju mogućnost izuzeti određena poduzeća ili čitave sektore iz svog portfelja zbog njihovog štetnog utjecaja na interesne skupine ili okoliš [Ivanišević Hernaus, 2016].

Bolibok [2021] navodi kako društvena odgovornost banaka podrazumijeva odgovornost pojedinih institucija za sigurnost sredstava koja su im povjerena, ali i odgovornost cjelokupnog bankarskog sektora za stabilnost financijskog sustava. Nwankwo [prema McDonald i Lai, 2011] smatra da banke moraju biti društveno odgovorne prema višestrukim dionicima; moraju maksimalizirati profit za dioničare, održati likvidnost, moraju zadovoljiti potražnju deficitarnog sektora za kreditima i ispuniti zahtjeve regulatora te doprinijeti razvoju gospodarstva. Društvena odgovornost banaka može se promatrati i u sklopu njihovih najvažnijih ciljeva; postizanje i održavanje stabilnosti cijena, održavanje deviznih tečajeva i financijske stabilnosti, rast BDP-a i zaposlenosti, funkcioniranje platnog prometa [Jalšenjak i Krkač, 2016, str. 556]. Buallay [2020] ističe da je ESG u bankarskom sektoru više fokusiran na društvena pitanja s ciljem stjecanja društvene podrške koja će doprinijeti održivosti poslovanja banaka u budućnosti.

Kumar i Prakash [2019] ističu da bankarski sektor ima ključnu ulogu u promicanju održivog razvoja budući da djeluje kao posrednik u gospodarskom razvoju. Banke imaju neizravan i izravan utjecaj na okoliš. Investicijske i kreditne aktivnosti neizravno utječu na okoliš, prilikom odobravanja kredita koji će se koristiti u ekološki prihvatljive svrhe kao što su poboljšanje izolacije zgrade, učinkovitiji sustav grijanja, postavljanje solarnih panela.Izravan utjecaj na okoliš vidljiv je kroz potrošnju papira i energije, gospodarenje otpadom, kod procesa nabave i vrsti korištenja prijevoznih sredstava. Važnu ulogu bankarski sektor ima i kod društvenog aspekta, banke bi trebale težiti razvoju novih proizvoda i usluga koji će biti namijenjeni migrantima, mladima, socijalno isključenim osobama, mikropoduzetnicima i drugim različitim segmentima. Dobar primjer financijske uključenosti jest mikrofinanciranje. Prema Kumaru i Prakashu [2019] banke sve više u nefinancijskim izvješćima ističu inicijative vezane uz financijsku pismenost. Partnerstvo i umreženost su ključni elementi DOP-a, banke iskazuju svoju predanost DOP-u članstvom u različitim mrežama kao što su CSR-Europe, Global Compact, Eurosif [eng. European Sustainable Investment Forum], United Nations Environment – Finance Initiative. Uspješnost banaka ovisi o povjerenju klijenta pa se više pozornosti posvećuje analizi i provjeri pri odobravanju financijskih sredstava, banke razmatraju što će financirati i kakve će to posljedice imati na društvo i okoliš [EBF, 2008].

Međutim, može se istaknuti i nekoliko barijera koje otežavaju bankama da primjene koncept društveno odgovornog poslovanja. U mnogim zemljama ne postoje regulatorni zahtjevi za društvenu odgovornost i odgovornost prema okolišu. Tran [2014] ističe kako znanje i percepcija također se smatraju jednom vrste prepreke. Ukoliko menadžeri i zaposlenici banaka nisu

upoznati s posljedicama neprovođenja DOP aktivnosti i DOP izvješćivanja, ne može se ni očekivati da će banke biti društveno odgovorne.[]Mnoge male banke ne ulažu nikakav napor u izračun troškova društveno odgovornog poslovanja i zbog toga ne mogu ni znati da će korist vjerojatno biti veća od troškova [Tran, 2014].

2.1. DRUŠTVENO ODOGOVORNO POSLOVANJE BANKARSKOG SEKTORA NA PODRUČJU REPUBLIKE HRVATSKE

Razvoj i primjena društveno odgovornog poslovanja u RH započela je nakon 1990. godine, a interes se dodatno pojačao 2004. godine kada je Hrvatska dobila status zemlje kandidatkinje za ulazak u Europsku uniju [HUP, 2013, str. 30]. Kundid je 2012. godine provela istraživanje u kojem je analizirala sadržaj internetskih stranica, godišnjih i društvenih izvješća deset banaka iz RH. Nakon preliminarne analize, autorica je uočila da male banke imaju nedovoljno razvijenu praksu objave informacija vezanih uz društvenu odgovornost, stoga su takve banke bile isključene iz uzorka. Na temelju zaključka autorice, primjećuje se da banke u RH uglavnom povezuju društveno odgovorno djelovanje s humanitarnim i filantropskim aktivnostima. Osim toga, autorica ističe da su banke više orijentirane prema iznošenju stavova o pitanjima društvenog značaja, nego provođenju konkretnih akcija [Kundid, 2012].

Rogošić i Kundid [2012] provele su istraživanje čija je tema bila praksa izvještavanja banaka o društvenoj odgovornosti. Analizom izvještavanja o društvenoj odgovornosti, utvrđeno je da su banke najviše usmjerene na objavljivanje aktivnosti vezanih uz uključenost u lokalnu zajednicu. Velike banke, u usporedbi sa srednjim i malim bankama, u prosjeku objavljuju više informacija o društveno odgovornom poslovanju. Međutim, uspoređujući objavljene aktivnosti matičnih banaka (većinskih vlasnika šest velikih banaka) u inozemstvu, primijećeno je da velike banke u Hrvatskoj manje se angažiraju u humanitarnim projektima, razvoju lokalne zajednice te promicanju politika zaštite okoliša, motiviranju i edukaciji zaposlenika. Autorice ističu da banke u Hrvatskoj skromno publiciraju svoje društveno odgovorne aktivnosti, a nedovoljna zainteresiranost i neosviještenost o prednostima DOP-a jedni su od razloga za takvu praksu.

Grudić Kvasić, Cerović i Olgić Draženović su proveli istraživanje o društveno odgovornom poslovanju banaka u RH, fokusirajući se na izvještavanje banaka o DOP aktivnostima putem interneta. Prema rezultatima njihovog istraživanja iz 2016. godine, 24 banke, odnosno 87% njih su izvještavale o DOP aktivnostima [Grudić Kvasić, Cerović i Olgić Draženović, 2016]. Na temelju indeksa izvještavanja o DOP-u, srednje velike banke su objavile najviše informacija, slijede ih velike banke, dok su male banke zauzele posljednje mjesto, što potvrđuje i rezultate istraživanja koje su dobile Rogošić i Kundić.

Topić je 2019. godine proveo analizu primjene načela društveno odgovornog poslovanja u bankarskom sektoru, istraživao je izvještavaju li o navedenom konceptu banke na svojim internetskim stranicama te o kojem području iz DOP-a najviše izvještavaju. Rezultati istraživanja ukazuju da većina banaka najviše izvještava o području poslovne strategije i tržišnih odnosa, dok je izvještavanje o zaštiti okoliša najmanje zastupljeno. Rezultati ukazuju na to i da većina banaka u određenoj mjeri primjenjuje načela društveno odgovornog poslovanja [Topić, 2019].

3. METODOLOGIJA ISTRAŽIVANJA

Cilj istraživanja ovog rada jest utvrditi koliko su banke u RH društveno odgovorne, odnosno pružiti uvid kojim područjima najviše posvećuju pozornosti i koliko aktivno primjenjuju prakse

društveno odgovornog poslovanja. Kako bi se utvrdila razina društvene odgovornosti banaka pretraživale su se službene web stranice banaka, njihovi godišnji izvještaji, izvještaji o održivosti te ostali internetski portali koji izvještavaju o društveno odgovornim aktivnostima banaka. Za potrebe istraživanja koristio se upitnik Hrvatskog indeksa održivosti koji se primjenjuje za utvrđivanje razine održivosti poduzeća u Hrvatskoj. Upitnik se sastoji od pet područja: (1) upravljanje, (2) radna okolina, (3) okoliš, (4) odnosi sa zajednicom i (5) ljudska prava. Područje upravljanje podijelilo se na održivi razvoj u strateškim dokumentima poduzeća i na tržišne odnose. Ukoliko banke primjenjuju, odnosno izvještavaju o nekoj od navedenih aktivnosti, dodijeljena je vrijednost 1, odnosno jedan bod, a u obrnutoj situaciji 0 bodova. Ukupno je bilo moguće skupiti 42 boda, od čega 7 bodova se odnosi na održivi razvoj u strateškim dokumentima, 6 bodova na tržišne odnose, 6 bodova na odnose sa zajednicom, 7 bodova na okoliš, 13 bodova na radnu okolinu te 3 boda na ljudska i dječja prava. U istraživanju su obuhvaćene banke koje su zadovoljile unaprijed definirane kriterije: (1) banka posluje s pozitivnim rezultatom; (2) banka na internetskim stranicama izvještava o DOP-u; (3) banka je članica organizacija koje promiču prakse DOP-a.

Tablica 1 prikazuje popis banaka koje su analizirane. U uzorak je odabrano 10 banaka te je time obuhvaćeno 94% ukupne aktive bankarskog sektora. Iz analize je isključena Nova hrvatska banka budući da se 03. srpnja 2023. godine pripojila Hrvatskoj poštanskoj banci [Jutarnji.hr, 2023]. Dodatno, iz analize je isključena Wüstenrot stambena štedionica d.d..

Tablica 1: Popis banaka uključenih u analizu

Redni broj	Naziv banke	Ukupna imovina	Udio u ukupnoj imovini %
1.	Addiko Bank d.d.	2.164.430	3,01
2.	Erste&Steiermärkische Bank d.d.	12.227.991	16,98
3.	Hrvatska poštanska banka d.d.	4.398.791	6,11
4.	Karlovačka banka d.d.	428.388	0,59
5.	OTP banka d.d.	7.143.052	9,92
6.	Podravska banka d.d.	619.380	0,86
7.	Privredna banka Zagreb d.d.	15.239.714	21,17
8.	Raiffeisenbank Austria d.d.	6.076.983	8,44
9.	Slatinska banka d.d.	230.660	0,32
10.	Zagrebačka banka d.d.	19.175.453	26,63
		UKUPNO	**94,03**

Izvor: izrada autorica prema podacima HNB-a, 2023.

4. REZULTATI ISTRAŽIVANJA I RASPRAVA

Najveći broj bodova postigle su veće banke u stranom vlasništvu, uključujući Raiffeisen banku, Zagrebačku banku, Privrednu banku Zagreb, OTP banku i Erste&Steiermärkische Bank. Među bankama koje su u domaćem vlasništvu, ističu se HPB i Slatinska banka. Pritom, analiza tržišnog udjela ukazuje na to da banke s većim udjelom češće izvještavaju o primjeni društveno odgovornog poslovanja. Banke koje se nalaze u domaćem vlasništvu u znatno manjoj mjeri izvještavaju o praksama društveno odgovornog poslovanja te je primijećeno da se radi o manjim bankama. Izuzetak jest HPB koja je ostvarila 40 bodova. Rezultati istraživanja ukazuje na utjecaj veličine tržišnog udjela i vlasničke strukture na primjenu koncepta društveno odgovornog poslovanja. Promatrajući područja obuhvaćena istraživanjem, primjećuje se da su

banke najviše uključene u aktivnosti društveno odgovornog poslovanja u sljedećim domenama: održivi razvoj u strateškim dokumentima, tržišni odnosi i odnosi sa zajednicom. Dobiveni rezultati potvrđuju rezultate prethodnih istraživanja provedenih u RH.

Održivi razvoj u strateškim dokumentima

Promatrajući područje održivog razvoja u strateškim dokumentima, vidljivo je da sve analizirane banke imaju etički kodeks ili kodeks ponašanja. Kodeksi svjedoče o njihovom angažmanu u promicanju odgovornog poslovnog ponašanja. U slučaju kršenja etičkog kodeksa ili drugih pravilnika i politika, banke su uspostavile interne mehanizme za rješavanje nepravilnosti, najčešće u obliku posebnih odjela koji su zaduženi za taj posao. Sve banke imaju u sklopu godišnjeg izvješća izjavu o primjeni kodeksa korporativnog upravljanja. Strateški dokumenti također uključuju smjernice i sustave za upravljanje kvalitetom, okolišem, zdravljem i sigurnošću na radnom mjestu, te upravljanje sigurnošću informacija. Prisutnost ovih smjernica i sustava ukazuje na odgovorno ponašanje prema internim i eksternim dionicima. Banke s većim tržišnim udjelom objavljuju izvješća o nefinancijskim informacijama te imaju posebne rubrike na svojim web stranicama posvećene društveno odgovornom poslovanju. Ostale banke pružaju samo nekoliko informacija putem godišnjih izvješća. Manje banke ne izvještavaju o društveno odgovornom poslovanju prema međunarodnim smjernicama. Kod većih banka najčešće korištene smjernice jesu GRI standardi. Također, prilikom izvještavanja nekoliko banaka uzima u obzir Non-Financial Reporting Directive (skraćeno: NFRD) i Corporate Sustainability Reporting Directive (skraćeno: CSRD). Sve banke su članice barem jedne organizacije koja promiče prakse društveno odgovornog poslovanja. Banke u domaćem vlasništvu najčešće su samo članice Hrvatske udruge banaka, dok su ostale članice Global Compact-a ili Hrvatskog poslovnog savjeta za održivi razvoj.

Tržišni odnosi

Sve analizirane banke primjenjuju nekoliko politika koje reguliraju njihove odnose s ostalim dionicima. Najčešće razvijene politike obuhvaćaju zaštitu privatnosti klijenata i odgovorno oglašavanje i komunikaciju. Banke vrlo malo izvještavaju o svom odnosu prema konkurenciji, ali ipak često ističu u etičkim kodeksima da se pridržavaju pravila tržišnog natjecanja. Također, prilikom odabira dobavljača, analizirane banke traže da se pridržavaju načela društvene i korporativne odgovornosti. Sve banke mjere zadovoljstvo svojih klijenata s ciljem poboljšanja kvalitete usluga te ispunjenja očekivanja i potreba klijenata. Najčešći način utvrđivanja zadovoljstva klijenata je analizom prigovora, a neke banke koriste i metodu mystery shopping te provode ankete kako bi ispitale mišljenje i zadovoljstvo klijenata. Odgovorno poslovanje banaka prema društvu manifestira se kroz različite aktivnosti koje provode, posebice u vezi s financijskom pismenošću. Banke često objavljuju različite edukativne materijale o financijskoj pismenosti na svojim službenim web stranicama, organiziraju edukacije u suradnji s vrtićima, srednjim školama i fakultetima te sudjeluju na manifestacijama kojima je cilj povećanje financijske pismenosti. Osim toga, banke pokazuju svoju brigu o potrebama različitih segmenata društva i okoliša putem ponude posebnih proizvoda. Velik broj banaka nudi kredite namijenjene umirovljenicima ili studentima, kredite za kupnju električnih vozila, turističke kredite te stambene kredite s ciljem poboljšanja energetske učinkovitosti.

Odnosi sa zajednicom

Uspostava pozitivnih odnosa sa zajednicom ima ključnu ulogu u izgradnji povjerenja prema bankarskom sektoru, stoga je od iznimne važnosti njegovati te odnose. Banke koje su

obuhvaćene ovim istraživanjem aktivno komuniciraju sa zajednicom na različite načine. Sudjeluju na konferencijama, odazivaju se na lokalne događaje te redovito surađuju s udrugama kako bi pomogle u rješavanju društvenih problema. Također, često ostvaruju partnerstva s visokoobrazovnim institucijama te podržavaju njihove projekte i sudjeluju u njihovim programima. Kroz sponzorstva i donacije, banke također pružaju podršku kulturnim, sportskim, obrazovnim, gospodarskim, znanstvenim i ekološkim projektima. Informacije o iznosima donacija i sponzorstava po različitim područjima dostupne su u izvješćima o održivosti. Važno je napomenuti da se zaposlenici bankarskog sektora aktivno uključuju u različite volonterske aktivnosti, poput čišćenja okoliša ili volontiranja u domovima za umirovljenike i domovima za djecu.

Okoliš

Banke su uključile zaštitu okoliša u svoje modele poslovanja. Velike banke su razvile politike zaštite okoliša i aktivno sudjeluju u očuvanju okoliša. Većina banaka uključuje ciljeve zaštite okoliša u svoju poslovnu strategiju. Banke također poduzimaju određene korake kako bi smanjile svoj utjecaj na klimatske promjene, kao što su kupovina električnih vozila i poticanje zaposlenika da dolaze na posao biciklima ili romobilima ako je to moguće. Uvodi se i LED rasvjeta, postavljaju fotonaponske ćelije i regulira temperatura u radnim prostorima kako bi se povećala energetska učinkovitost. Budući da banke ne obavljaju proizvodnu djelatnost, već pružaju usluge, najveći izvor otpada proizlazi iz korištenja papira i elektroničke opreme. Banke se trude riješiti taj problem kroz korištenje recikliranog papira i tonerskih uložaka te digitalizacijom poslovanja i poticanjem klijenata na online komunikaciju. Između ostalog, banke organiziraju edukacije i radionice kako bi potaknule svoje zaposlenike na očuvanje okoliša, fokusirajući se na teme poput ESG, energetska učinkovitost i pravilno odlaganja otpada.

Radna okolina

Kako bi banke pružile bolju podršku svojim djelatnicima i omogućile im ostvarivanje visokih radnih standarda, implementiraju različite sustave za evaluaciju njihove uspješnosti. Većina analiziranih banaka izvještava o ulaganjima u obrazovanje svojih zaposlenika, navodeći broj zaposlenika koji su prošli edukacije te ukupan broj sati posvećenih obrazovanju. Osim internih edukacija, banke također omogućuju svojim zaposlenicima sudjelovanje na različitim stručnim edukacijama i konferencijama. Zaposlenici u bankarskom sektoru educiraju se o sprječavanju pranja novca i financiranju terorizma, prevenciji korupcije i mita, kao i o komunikacijskim, organizacijskim i liderskim vještinama. Osim toga, educiraju se o poslovnoj etici, sustavima upravljanja koji su povezani s radničkim pravima, zaštiti okoliša te suzbijanju predrasuda i diskriminacije. Sve analizirane banke imaju razvijenu politiku raznolikosti i nediskriminacije, a neke od njih navode ove vrijednosti i unutar svojih etičkih kodeksa. Banke nastoje i postići rodnu ravnopravnost i povećati broj žena na upravljačkim pozicijama. Kroz istraživanje je utvrđeno da nekolicina banaka primjenjuju pozitivne mjere kod zapošljavanja osoba u nepovoljnom položaju na tržištu rada. Najčešće zapošljavaju osobe s invaliditetom ili podržavaju projekte vezane uz njihovo zapošljavanje. Banke nastoje poboljšati životni standard svojih zaposlenika pružajući različite pogodnosti kao što su dopunsko zdravstveno osiguranje, nagrade, sufinanciranje školovanja, povoljnije bankarske usluge i uvjeti kreditiranja. S obzirom na važnost postizanja ravnoteže između privatnog i poslovnog života, banke koje su obuhvaćene istraživanjem omogućuju rad od kuće, slobodan dan za prvi dan škole ili vrtića, sufinanciranje vrtića te nude popuste za sportske aktivnosti. Kada je riječ o nagradama i certifikatima vezanim uz kvalitetu radne okoline, samo male banke obuhvaćene istraživanjem

trenutno nemaju nijednu nagradu. Većina banaka posjeduje certifikat "Poslodavac partner", a neke banke dobitnice su nagrade kao što su "Top Employer", "Poslodavac prijatelj obitelji" i "Employer Brand Awards Adria".

Ljudska i dječja prava

Većina banaka ima uspostavljene smjernice za zaštitu ljudskih i dječjih prava. Analizom je utvrđeno da banke vrlo malo izvještavaju o zaštiti ljudskih i dječjih prava, nema dostupnih informacija o aktivnostima koje se provode na tom području.

5. ZAKLJUČAK

Društvena odgovornost u poslovanju banaka je neizbježna budući da su banke važan faktor gospodarstva s ekonomskog i etičkog aspekta. Banke su temeljni stup financijskog sustava Republike Hrvatske, stoga njihova uloga u osiguranju stabilnosti financijskog sustava direktno utječe na mogućnost gospodarskog rasta i napretka zemlje. Upravo zbog ovakve važnosti, društvena odgovornost u poslovanju banaka postaje ključna. Izazovi poput pranja novca, korupcije, financiranje terorizma, teškoće u otplati kredita i nedovoljna zaštita potrošača, izlažu banke nepovoljnim situacijama. U takvim kontekstima, primjena praksi društveno odgovornog poslovanja postaje svojevrsna obrambena strategija. Osnovna svrha ovog istraživanja bila je utvrditi koliko su banke u Republici Hrvatskoj društveno odgovorne te istražiti u kojim specifičnim područjima DOP-a banke najaktivnije djeluju. Domaće banke pokazuju nižu razinu izvještavanja o praksama društvene odgovornosti, a ovakav trend posebno se ističe kod manjih banaka. Izuzetak čini Hrvatska poštanska banka, koja je postigla 40 bodova. Najveći broj bodova, odnosno maksimalan broj bodova ostvarila je Raiffeisenbank Austria d.d., a od malih banaka istaknula se Slatinska banka s 28 bodova. Rezultati istraživanja upućuju na utjecaj tržišnog udjela i vlasničke strukture na implementaciju koncepta društveno odgovornog poslovanja. Analizirajući rezultate, vidljivo je da banke najviše pažnje posvećuju aspektima lokalne zajednice, tržišta i integraciji održivog razvoja u svoje strateške dokumente. Suprotno tome, najmanje pažnje usmjeravaju prema pitanjima ljudskih i dječjih prava te zaštite okoliša. Rezultati ovog istraživanja vrlo su slični onim dobivenim u prethodnim istraživanjima, ukazujući na to da se situacija nije promijenila. Manje banke i dalje zaostaju za većim, a zaštita okoliša i ljudskih prava ostaju slabo pokrivena područja društveno odgovornog poslovanja. Ograničenje ovog istraživanja jest da je analiza obuhvatila samo polovicu banaka koje posluju u RH. Ovo istraživanje temelji se samo na informacija koje su dostupne na internetu. Radi postizanja još pouzdanijih rezultata, preporučljivo je u budućim istraživanjima provesti intervjue i ankete s djelatnicima bankarskog sektora. Takav pristup povećao bi vjerodostojnost rezultata.

REFERENCE

[1] Bolibok, P. (2021). The impact of social responsibility performance on the value relevance of financial data in the banking sector: evidence from Poland. *Sustainability,* 13(21), 12006.

[2] Buallay, A. (2020). Sustainability reporting and firm's performance: Comparative study between manufacturing and banking sectors. *International Journal of Productivity and Performance Management,* 69(3), 431-445.

[3] Europska bankovna federacija [EBF]. (2008). Corporate Social Responsibility. https://www.ebf.eu/wp-content/uploads/2017/01/csr-2008-00975-01-E.pdf, preuzeto: [11. svibnja 2023]
[4] Grudić Kvasić, S.; Cerović LJ.; Olgić Draženović, B. (2016). Online corporate social responsibility reporting in the Croatian banking sector. *Int'l Pub. Admin. Rev.*, 14, 9.
[5] Hrvatska udruga poslodavaca [HUP] (2013). Društveno odgovorno poslovanje za sve, https://www.hup.hr/EasyEdit/UserFiles/Petra%20Senti%C4%87/Nacionalni%20DOP%20HR.pdf, preuzeto: [27. travnja 2023]
[6] Ivanišević Hernaus, A. (2016). Društvena odgovornost u financijskom sektoru. *EFZG working paper series*, (08), 1-17.
[7] Jalšenjak B.; Krkač K. (2016). *Poslovna etika, korporacijska društvena odgovornost i održivost (2. izd.).* MATE, Zagreb.
[8] Jutarnji.hr (2023). Nova hrvatska banka (NHB) uspješno je pripojena Hrvatskoj poštanskoj banci (HPB): Za klijente se mijenja samo jedna stvar, https://novac.jutarnji.hr/novac/aktualno/nova-hrvatska-banka-nhb-uspjesno-je-pripojena-hrvatskoj-postanskoj-banci-hpb-za-klijente-se-mijenja-samo-jedna-stvar-15351553, preuzeto: [09. kolovoza 2023]
[9] Kundid, A. (2012). Društveno odgovorno poslovanje banaka u Republici Hrvatskoj. *Ekonomska misao i praksa*, (2), 497-528.
[10] Kundid, A. (2014). Etičko bankarstvo–novi koncept bankarstva. *U: Ćurak, M., Kundid A., Visković, J.(2014):„Financije nakon krize,* 243-265.
[11] Kumar, K.; Prakash, A. (2019). Examination of sustainability reporting practices in Indian banking sector. *Asian Journal of Sustainability and Social Responsibility*, 4(1), 1-16.
[12] McDonald, L. M.; Hung Lai, C. (2011). Impact of corporate social responsibility initiatives on Taiwanese banking customers. *International Journal of Bank Marketing*, 29(1), 50-63.
[13] Rogošić, A.; Kundid, A. (2012). Izvještavanje o društvenoj odgovornosti banaka u Hrvatskoj. *Praktični menadžment: stručni časopis za teoriju i praksu menadžmenta,* 3(2), 15-20.
[14] Steurer, R.; Margula, S.; Martinuzzi, A. (2008). Socially Responsible Investment in EU Member States: Overview of government initiatives and SRI experts' expectations towards governments. *Analysis of national policies on CSR, in support of a structured exchange of information on national CSR policies and initiatives. Final report to the EU High-Level Group on CSR provided by the Research Institute for Managing Sustainability.* Vienna University of Economics and Business.
[15] Topić, J. (2019). Društveno odgovorno poslovanje banaka u Republici Hrvatskoj (Diplomski rad, Ekonomski fakultet, Split), https://zir.nsk.hr/islandora/object/efst:3151, preuzeto: [15. lipnja 2023]
[16] Tran, Y. T. H. (2014). CSR in banking sector a literature review and new research directions. *International Journal of Economics, Commerce and Management*, Vol. II, Issue 11.

Review article / Pregledni rad

MIGRATING DATA TO THE CLOUD: AN ANALYSIS OF CLOUD STORAGE PRIVACY AND SECURITY ISSUES AND SOLUTIONS

MARIJA KUŠTELEGA
University of Zagreb
Faculty of Organization and Informatics
Pavlinska 2, 42000 Varaždin, Croatia
marija.kustelega@foi.unizg.hr

RENATA MEKOVEC
University of Zagreb
Faculty of Organization and Informatics
Pavlinska 2, 42000 Varaždin, Croatia
renata.mekovec@foi.unizg.hr

ABSTRACT

The rise of a digital economy has transformed how individuals do business and carry out daily tasks, including how data is maintained. Because of the vast amount of data that organizations own, cloud storage, a component of the cloud computing paradigm, has emerged as a feasible solution to many businesses' data storage concerns. Despite this, organizations are still cautious about moving all of their data to the cloud due to security concerns, particularly since data management is outsourced to third parties. The aim of this paper is to provide an overview of current challenges in the field of cloud storage privacy and security, with an emphasis on issues related to data confidentiality, integrity, and availability. Using a comprehensive literature study, this research investigates innovative strategies for creating a secure cloud storage environment. The idea of maintaining privacy and data security through the very design of the services, or through the so-called "privacy by design" approach, is explained while avoiding getting into the technical details of how the algorithms and presented solutions work.

KEYWORDS: digital economy, cloud, storage, privacy, security, challenges, solutions

1. INTRODUCTION

The Digital Economy Report 2021 provides insight into the development and policy implications of cross-border digital data flows, focusing on rapidly expanding digital technologies, which have become a vital resource for today's economy [United Nations Conference on Trade and Development (UNCTAD), 2021]. Cloud computing is listed in the report as one of the critical fuels of the digital economy, particularly regarding the expansion of the cloud market. A 2019 survey of 400 professionals from industries worldwide revealed 84% used the cloud for data storage or backup, while 5% planned to implement it within the next six months [Statista, 2022]. With the increasing use of cloud technology across various

industries, migrating data to the cloud poses significant privacy and security challenges.

1.1. DIGITAL ECONOMY AND CLOUD COMPUTING

The digital economy has shifted from goods and services to information production, thereby enabling new ways of creating value [UNCTAD, 2019]. As a result, this data-driven economy emerges due to the benefits it offers for strategic trade [Ciuriak, 2020].

The digital economy consists of three main components [UNCTAD, 2019]:

- core aspects (digital infrastructure and hardware),
- digital and information technology sectors (digital platforms, payments etc.),
- and the broader idea of digitized sectors (places where digital goods and services are primarily used, like finance, tourism, and transport).

The cloud computing paradigm has become an important aspect of the growing digital economy due to its tight link to technology stated in all three components. The National Institute of Standards and Technology (NIST) describes cloud computing as a concept for on-demand network access to shared computer resources, including cloud storage, as one example of these resources [Mell and Grance, 2011].

Consideration for the legal obligations should be analyzed when storing data. In Article 5 of Regulation (EU) 2016/679 of the European Parliament and of the Council of 27 April 2016 on the protection of natural persons with regard to the processing of personal data and on the free movement of such data, and repealing Directive 95/46/EC (General Data Protection Regulation - GDPR), data processing principles such as the storage of personal data and measures to prevent unlawful processing are outlined. In order to promote data sharing among enterprises, the European Union (EU) enacted the Data Governance Act (DGA) and is drafting the Data Act proposal; nevertheless, these regulations may compromise data privacy under the GDPR [Eur-lex.com, 2022]. Moreover, it is important to mention the Free Flow of Non-Personal Data Regulation, which enabled non-personal data storage, processing, and transfer, as well as the development of Switching Cloud Providers and Porting Data (SWIPO) codes of conduct for enforcing data portability across cloud providers [Eur-lex.com, 2022]. Additionally, one of the Data Act proposal's specific goals deals with problem of simplifying cloud and edge service switching, enabling organizations to move data and assets between providers to build trust and facilitate data sharing [Eur-lex.com, 2022]. These principles are crucial for the further development of the digital economy.

1.2. CIA triad

According to the NIST: "Information system-related security risks arise from the loss of confidentiality, integrity, or availability of information or information systems" [Chandramouli and Pinhas, 2020]. The CIA triad, a commonly used framework for identifying security risks, stands for [Fortinet, n.d.]:

- **C**onfidentiality: keeping data hidden or private from unauthorized users,
- **I**ntegrity: ensuring accurate and dependable data that has not been altered,
- **A**vailability: proper and on-time functioning of systems and applications.

NIST security recommendations for storage infrastructures include data protection using encryption, regular backup testing to verify integrity, and multiple authentication servers to ensure availability [Chandramouli and Pinhas, 2020]. In this regard, Article 32 of GDPR [L

119/1] outlines technical and organizational measures for ensuring the CIA triad, including pseudonymization, encryption, regular testing, and evaluation.

The aim of this paper is to provide an overview of current challenges in the field of cloud storage privacy and security, focusing on issues related to data confidentiality, integrity, and availability. The following research questions (RQs) were developed to achieve this goal:

- RQ1: What are the key challenges with cloud storage privacy and security issues related to data confidentiality, integrity, and availability?
- RQ2: What modern solutions are being developed for data storage security and privacy protection in the cloud?

The remainder of the paper is structured as follows: Section 2 addresses applied research methodology; Section 3 presents results and findings; Section 4 discusses main challenges; Section 5 presents literature solutions; and Section 6 concludes the research article.

2. METHODOLOGY

The literature review was conducted utilizing the Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA) methodology, divided into search, screening, and data extraction phases [Moher et al., 2009]. Within the search phase, the appropriate search string was used to discover relevant publications on privacy and cloud data storage for business purposes. Scopus, WoS, and Science Direct databases were searched for articles that satisfied search criteria, limited to English-language publications published in the last five years, beginning in 2018 and ending in July 2023. Figure 1 presents the PRISMA methodology's steps graphically and provides thorough explanations.

Figure 1. PRISMA diagram with results of the literature search and screening

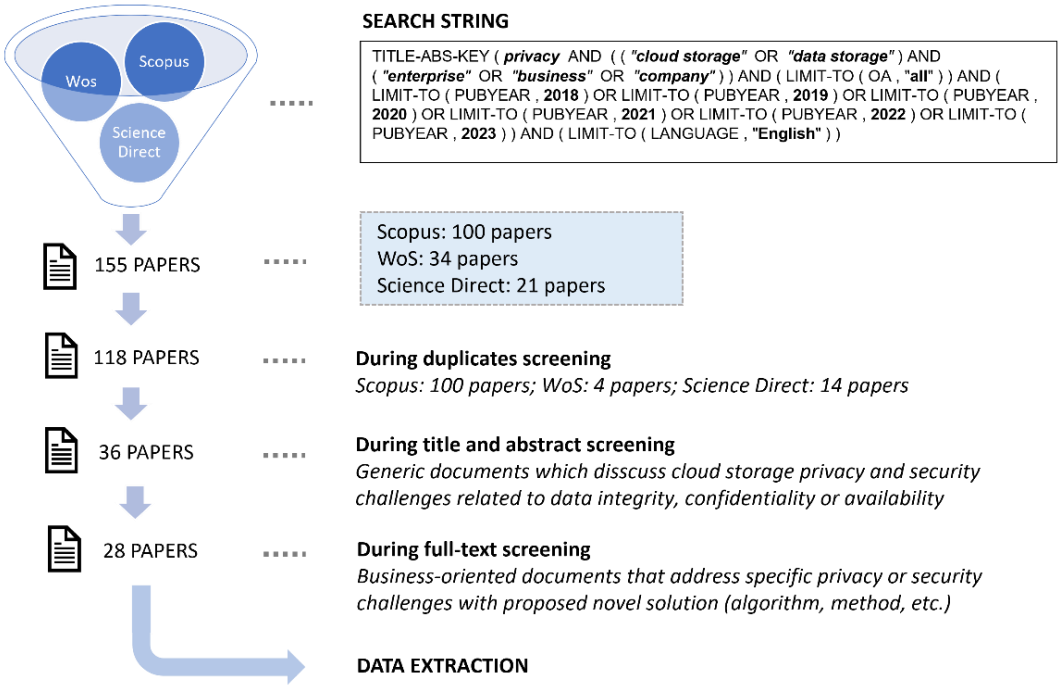

Source: Authors

The articles were analyzed by duplicate screening, title and abstract screening, and full-text screening. Inclusion and exclusion criteria were used to narrow the pool of articles. Articles had to address cloud storage challenges and at least one of the CIA triad issues to be included for further analysis. The analysis excluded studies that did not meet the search criteria or referred to articles with systematic literature reviews without presenting their own solution. Articles that met the inclusion and exclusion criteria were extracted and analyzed.

3. RESULTS

This study examined 28 papers to provide a systematic review of challenges and solutions associated with cloud storage over the last five years. The results were processed in the following order: identification of challenges, categorization of challenges, and presentation of solutions. Firstly, cloud storage issues were identified using the CIA triad. Table 1 depicts an overview of the main challenges mapped into the CIA triangle, where "C" refers to confidentiality, "I" to integrity, and "A" to data availability issues. If the security issues were addressed in publications, they were labeled with "x"; otherwise, the cells were left blank.

Table 1. Identification of challenges

No	Author(s)	Main challenges	C	I	A
1.	Liu et al. (2022)	Protect highly sensitive data during public sharing.	x	x	
2.	Chen et al. (2022)	Protect data shared between enterprises.	x	x	
3.	Vo et al. (2021)	Protect database and enable encrypted keyword search.	x		
4.	Rauthan & Vaisla (2021)	Ensure user data confidentiality with robust database.	x		
5.	Khashan (2020)	Secure outsourced and shared cloud data.	x	x	
6.	Li et al. (2019)	Protect smart grid data and enable keyword search.	x		
7.	Miao et al. (2018)	Support multi-keyword search and result verification.	x	x	
8.	Li et al. (2020)	Ensure data integrity scheme with quantum security.		x	
9.	Challagidad & Birje (2020)	Provide multi-authority access control for user data.	x	x	
10.	Kumar & Shafi (2020)	Protect stored data with RSA public key cryptosystem.	x	x	
11.	KL & Nair (2019)	Secure locking system for critical data.	x	x	x
12.	Yadav et al. (2019)	Provide reliable system for monitoring cloud data.	x	x	
13.	Liang et al. (2018)	Secure sharing and collaboration in healthcare systems.	x	x	x
14.	Mohammed & Abed (2020)	Secure storage of cloud data at rest.	x		
15.	Berrima et al. (2018)	Ensure data privacy and user authentication.	x		
16.	Yan et al. (2021)	Safeguard uploader privacy in group-shared data.	x	x	
17.	Divya et al. (2019)	Protect storage and enable keyword data retrieval.	x	x	
18.	Wu et al. (2019)	Enable privacy and retrieval in pay-as-you-go model.	x	x	
19.	Pinheiro et al. (2018)	Build security architecture for cloud data monitoring.	x	x	x
20.	Zheng et al. (2022)	Provide access control for user attribute revocation.	x		
21.	Bian et al. (2022)	Safeguard sensitive data during audits.	x	x	
22.	Uddin et al. (2021)	Prevent cloud threats in virtualization platforms.	x	x	x
23.	Jl & Maria (2020)	Improve data integrity in dynamic cloud auditing.	x	x	
24.	Nithya & Rhymend Uthariaraj (2021)	Preserve data integrity and key-exposure in multiple cloud storage.	x	x	
25.	Almuzaini et al. (2022)	Improve key aggregate cryptosystem for health systems.	x	x	
26.	Zhang et al. (2020)	Ensure cloud audit protocol with group user privacy.	x	x	
27.	Tian & Wang (2020)	Ensure secure deletion of sensitive data.	x	x	
28.	Zhang et al. (2019)	Enhance privacy of Internet of Things (IoT) layers.	x	x	x

Source: Authors

The results showed that various industries have taken cloud security challenges into account. Most articles emphasized data integrity and confidentiality, with less focus on data availability issues. Further findings will be discussed in the sections that follow where first the categorization of privacy and security challenges is presented and then proposed solutions.

4. CATEGORIZATION OF PRIVACY AND SECURITY CHALLENGES

Companies often use multiple cloud storage to reduce costs and prevent vendor lock-in [Nithya & Rhymend Uthariaraj, 2021], but this requires security measures to protect sensitive data [KL and Nair, 2019]. This is particularly important for hospitals, banks, and IoT devices, which require verified data integrity for proper data analysis [Jl & Maria, 2020]. Based on a literature review, the recognized privacy and security challenges can be divided into four primary categories: monitoring, access control, data protection, and functionality challenges. In order to better visualize the main challenges, their graphic representation is shown in Figure 2.

Figure 2. Categorization of challenges

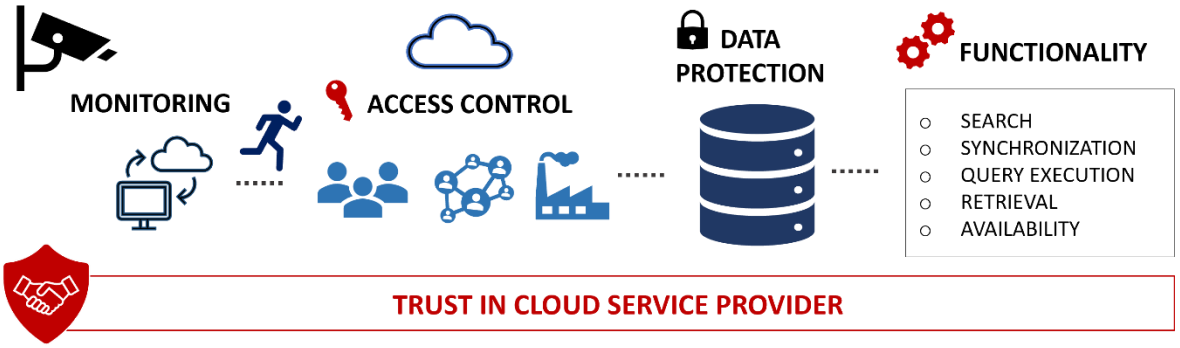

Source: Authors

According to this, all challenges can be connected to the larger problem of trust in service providers. Concerns related to monitoring, access control and data protection directly impact security and privacy. Despite not immediately jeopardizing safe storage, functional issues are identified as one of the obstacles to overcome when developing cloud storage systems.

4.1. MONITORING

Cloud service providers monitor and maintain a wide range of services for end users and businesses, making it challenging to track all cloud activities and perform efficient data security monitoring [Yadav et al., 2019]. Cloud service providers may seek for sensitive customer information during data integrity audits [Bian et al., 2022], return incorrect or irrelevant search results [Miao et al., 2018] or can easily fake authenticator to provide false proof of integrity [Zhang et al., 2020]. Data leakage may also occur when providers fail to destroy every copy of erased data, so users must be sure that they will delete all backups [Tian & Wang, 2020]. Sensitive data necessitates stronger privacy protection, but knowing when to do rigorous or less demanding checks remains difficult. It would be convenient if the user could choose when to execute further data integrity checks in the event of any security concerns. [Yadav et al., 2019]. According to Pinheiro et al. (2018), the security architecture must adjust the frequency of integrity checks based on the amount of trust in the cloud service provider. They underline the

significance of observing cloud activities and proposing dynamic integrity checks with respect to the learned service provider behavior. Attacks are another thing to keep an eye on because they cause severe problems. Authors have addressed challenges with various attacks, such as inference attack [Vo et al., 2021], quantum attack [Li et al., 2020], side-channel attacks [Li et al., 2019], and keyword guessing attack [Miao et al., 2018]. In virtualized cloud infrastructure is common the "velocity-of-attack", where security threats spread and escalate faster due to the expanded infrastructure [Uddin et al., 2021]. Jl & Maria (2020) highlighted the problem of launching a distributed denial-of-service (DDOS) attack, causing network congestion and degrading service quality. With a detailed study of a chosen protocol, Berrima et al. (2018) revealed an unidentified attack that endangers user privacy. Therefore, with continuous observation, it's possible to uncover previously hidden drawbacks and improve security. Furthermore, design systems should continuously monitor data and alert about potential attacks for ensuring storage security [Yadav et al., 2019].

4.2. ACCESS CONTROL

Due to the on-demand nature of cloud computing, it is essential to put strong security measures to regulate data access and prevent unauthorized access [Mohammed & Abed, 2020]. This applies to data transfer, where reliable verification and access control mechanisms need to be established [Almuzaini et al., 2022] and for better control of sensitive data, such as private medical data [Liang et al., 2018]. To ensure that vital data is safely kept in the cloud, it is crucial that only the authenticated user can access or download data [KL and Nair, 2019], so access structures should restrict data to only those users with matching attributes [Tian & Wang, 2020]. Furthermore, KL and Nair (2019) considered multi-authentication challenges with acceptable data availability, while Liang et al. (2018) explored blockchain and smart contracts for reliable data access when dealing with multiple users. Zheng et al. (2022) focused on cloud access control in sensor networks and vehicular ad hoc networks (VANET). Considering cost effectiveness, systems with verifier authentication, may demand storage of verifier's unique key pairs, resulting in higher storage costs [Bian et al., 2022]. Moreover, cloud service providers face challenges in authenticating users while maintaining privacy. For instance, enterprise cloud storage systems with multiple user roles can compromise employee privacy through group user-based auditing protocols [Zhang et al., 2020]. To protect their employees' private data, organizations must provide fine-grained access control [Challagidad & Birje, 2020]. Berrima et al. (2018) analyzed private access control protocols where authenticate users must confirm storage rights without revealing their identity.

4.3. DATA PROTECTION

Data security was acknowledged in the new NIST Framework 2.0 draft as one of the outcomes to achieve in the prevention phase, distinguishing between securing data at rest, in use, and in transit [National Institute of Standards and Technology, 2023]. Rarely used archived documents pose a challenge due to poor access, allowing them to be compromised without the owner's knowledge. Mohammed and Abed (2020) focused on securing cloud data at rest to prevent leaks, illegal access, and threats. This is crucial, especially in smart grid data, as records contain common keywords, making them vulnerable to attacks [Li et al., 2019]. In order to secure storage, Vo et al. (2021) researched padding strategies against inference attacks, such as monitoring cluster caches and setting timers before flushing. Smart grid data is unique in that it is often updated and typically contains a large number of attributes, demanding a safe search index for performing such alternations [Li et al., 2019]. Providing effective integrity checks in situations involving dynamic data operations is likewise highly difficult [Divya et al., 2019]. Cloud service providers can free up storage by deleting or hiding instances of data loss [Wu et

al., 2019], but this presents challenges for companies handling massive amounts of data. To ensure proper data handling, cloud service providers should follow appropriate practices for information assurance [Uddin et al., 2021], including modification and removal procedures. Patients' medical records, according to Liu et al. (2022), can be useful data sources for both researchers and healthcare providers. Shared data involves collaboration among several people, so Zhang et al. (2019) tackle the challenge of developing secure key sharing schemes in IoT systems, while Liang et al. (2018) underlined the importance of secure communication channels for requesting personal healthcare or insurance services, as well as enabling effective collaboration between them. In addition to sharing publicly available data, it's equally important to protect privacy when sharing data within or between organizations. Chen et al. (2022) dealt with ensuring safe data transfer between approved businesses, while Yan et al. (2021) investigated the issue of preserving file uploaders' anonymity in internal data shared between workgroups.

4.4. FUNCTIONALITY

It is difficult to design a database structure that is both secure and efficient [Rauthan & Vaisla, 2021]. An encrypted database limits the ability to query parts [Li et al., 2019], thus making traditional query execution extremely challenging [Rauthan & Vaisla, 2021]. It disables search functionality important for searching data gathered by smart grid devices, such as metering data [Li et al., 2019]. Divya et al. (2019) explore a "coordinate matching" keyword search strategy to gather linked documents; Vo et al. (2021) explore a search secure against inference attacks; and Miao et al. (2018) dealt with multiple keyword searches. Wu et al. (2019) examine safeguarding user privacy while enabling functionality like data retrieval and audits suitable for public utility cloud services, such as electricity, where customers pay based on storage volume and duration. Lack of agreement among participants can lead to availability issues, such as bottlenecks causing system crashes [Uddin et al., 2021]. Research on safe transmission after cloud server failures [Zhang et al., 2019] and ensuring data availability [KL & Nair, 2019] can help address these issues.

5. PROPOSED TRENDS FOR ADDRESSING PRIVACY AND SECURITY CHALLENGES

The authors primarily used encryption and digital signatures in their solutions, combined with methods to preserve integrity. To guarantee data security, KL & Nair (2019) introduced the Data Storage Lock Algorithm (DSLA), Wu et al. (2019) designed a privacy-preserving proof of storage for the pay-as-you-go business model, while Mohammed and Abed (2020) developed an encryption framework to defend cloud data at rest. Privacy preservation methods include certificateless auditing [Bian et al., 2022], enhanced integrity methods [Jl & Maria, 2020], and forward secure public auditing scheme to prevent key exposure attacks [Li et al., 2020]. To maintain uploader anonymity in group-shared data, Yan et al. (2021) developed a certificateless public auditing protocol, while Zhang et al. (2020) designed a group user privacy auditing protocol to prevent cloud server’s integrity falsification. Identity-based techniques include parallel key insulation [Nithya & Rhymend Uthariaraj, 2021] and sanitizable digital signatures [Liu et al., 2022]. Khashan (2020) introduced user-side encrypted file systems (OutFS) for secure data exchange, while Zhang et al. (2019) proposed compressed sensing fault-tolerant encryption for secure key sharing in IoT cloud systems. Some authors explored blockchain solutions for virtualization [Uddin et al., 2021], enterprise data sharing scheme [Chen et al., 2022], and a safe collaboration system for sharing health data [Liang et al., 2018]. A fine-

grained data deletion system with attribute association (ADAA) was proposed by Tian & Wang (2020) for secure data deletion. For data control, Yadav et al. (2019) proposed a monitor-based scheme, while Pinheiro et al. (2018) established a security architecture and protocol that dynamically modify checks based on trust in the cloud service provider. In terms of ensuring access control across multiple authorities, Challagidad and Birje (2020) created a hierarchy access structure for privacy protection, Berrima et al. (2018) introduced a corrected private access control, and Zheng et al. (2022) introduced a user attribute revocation strategy. For functionality issues, Vo et al. (2021) proposed encrypted document database search, while Li et al. (2019) focused on searchable smart grid data. For data retrieval, Divya et al. (2019) developed cloud storage with trust manager, while Miao et al. (2018) proposed verifiable multi-keyword search. Rauthan & Vaisla (2021) developed solution for efficient query execution, Kumar & Shafi (2020) proposed a modified RSA public key cryptosystem, and Almuzaini et al. (2022) developed a scalable key aggregate cryptosystem for health data protection.

6. CONCLUSION

This study is important since it identifies challenges and solutions related to privacy and security protection when using cloud storage. Secure cloud data storage face with monitoring, access control, data protection, and functionality challenges, each requiring a distinct strategy. While static data needs robust measures for safe storage, dynamic data needs procedures to avoid unauthorized changes. Many of these challenges are linked to the broader issue of trust in cloud service providers, demanding constant data monitoring. Proposed solutions for secure cloud storage like encryption, signatures, data sanitization and integrity methods follow guidelines presented in the NIST framework. These findings can serve as a reminder of the security risks associated with cloud storage with the aim of encouraging the implementation of presented solutions. Further research is needed to determine whether the concept of privacy by design, which seeks to provide security and privacy while maintaining high service functionality, can really be implemented.

REFERENCES

[1] Almuzaini, K. K., Sinhal, A. K., Ranjan, R., Goel, V., Shrivastava, R., & Halifa, A. (2022). Key Aggregation Cryptosystem and Double Encryption Method for Cloud-Based Intelligent Machine Learning Techniques-Based Health Monitoring Systems. *Computational Intelligence and Neuroscience*, 2022.

[2] Berrima, M., Lafourcade, P., Giraud, M., & Rajeb, N. B. (2018). Formal analysis of a private access control protocol to a cloud storage. *International Journal of Innovative Computing and Applications*, 9(3), 150-164.

[3] Bian, G., Guo, X., Li, R., Qu, W., & Zhao, Y. (2022).Certificateless Data Integrity Auditing in Cloud Storage with a Designated Verifier and User Privacy Preservation. *Electronics*, 11(23), 3901.

[4] Challagidad, P. S., & Birje, M. N. (2020). Efficient multi-authority access control using attribute-based encryption in cloud storage. *Procedia Computer Science*, 167, 840-849.

[5] Chandramouli, R., Pinhas, D. (2020). Security Guidelines for Storage Infrastructure (No. NIST Special Publication (SP) 800-209).*National Institute of Standards and Technology*.

[6] Chen, C. L., Yang, J., Tsaur, W. J., Weng, W., Wu, C. M., & Wei, X. (2022). Enterprise data sharing with privacy-preserved based on hyperledger fabric blockchain in IIOT's application. *Sensors*, 22(3), 1146.

[7] Ciuriak, D. (2020). Economic Rents and the Contours of Conflict in the Data-driven Economy. *Policy Brief, Centre for International Governance Innovation*, June.

[8] Divya, S. V., Shaji, R. S., & Venkadesh, P. (2019). A combined data storage with encryption and keyword based data retrieval using SCDS-TM model in cloud. *Malaysian Journal of Computer Science*, 32(3), 163-185.

[9] Eur-lex.com (2022). Proposal for a regulation of the European Parliament and of the Council on harmonised rules on fair access to and use of data (Data Act), https://eur-lex.europa.eu/legal-content/EN/TXT/HTML/?uri=CELEX:52022PC0068, downloaded: [August, 12th 2023]

[10] Fortinet (n.d.). CIA Triad, https://www.fortinet.com/resources/cyberglossary/cia-triad#:~:text=The%20three%20letters%20in%20%22CIA,and%20methods%20for%20creating%20solutions. , downloaded: [August, 12th 2023]

[11] Jl, J. D., & Maria, C. (2020). Data integrity method for dynamic auditing in cloud environment. *Indian Journal of Computer Science and Engineering*, 11(6), 843-850.

[12] Khashan, O. A. (2020). Secure outsourcing and sharing of cloud data using a user-side encrypted file system. *IEEE Access*, 8, 210855-210867.

[13] KL, A., & Nair, T. R. (2019). Data storage lock algorithm with cryptographic techniques. *International Journal of Electrical & Computer Engineering (2088-8708)*, 9(5).

[14] Kumar, Y. K., & Shafi, R. M. (2020). An efficient and secure data storage in cloud computing using modified RSA public key cryptosystem. *International Journal of Electrical and Computer Engineering*, 10(1), 530.

[15] L 119/1. n.d. Regulation (EU) 2016/679 of the European Parliament and of the Council of 27 April 2016 on the protection of natural persons with regard to the processing of personal data and on the free movement of such data, and repealing Directive 95/46/EC (General Data Protection Regulation).

[16] Li, H., Liu, L., Lan, C., Wang, C., & Guo, H. (2020). Lattice-based privacy-preserving and forward-secure cloud storage public auditing scheme. *IEEE Access*, 8, 86797-86809.

[17] Li, J., Niu, X., & Sun, J. S. (2019). A practical searchable symmetric encryption scheme for smart grid data. In *ICC 2019-2019 IEEE International Conference on Communications (ICC)* (pp. 1-6). IEEE.

[18] Liang, X., Shetty, S., Tosh, D., Bowden, D., Njilla, L., Kamhoua, C. (2018). Towards blockchain empowered trusted and accountable data sharing and collaboration in mobile healthcare applications. *EAI Endorsed Transactions on Pervasive Health and Technology*, 4(15).

[19] Liu, Z., Ren, L., Li, R., Liu, Q., & Zhao, Y. (2022). ID-based sanitizable signature data integrity auditing scheme with privacy-preserving. *Computers & Security*, 121, 102858.

[20] Miao, Y., Ma, J., Liu, X., Liu, Z., Shen, L., & Wei, F. (2018). VMKDO: Verifiable multi-keyword search over encrypted cloud data for dynamic data-owner. *Peer-to-peer Networking and Applications*, 11, 287-297.

[21] Mell, P., & Grance, T. (2011). *The NIST Definition of Cloud Computing, Special Publication 800-145, National Institute of Standards and Technology*, https://csrc.nist.gov/pubs/sp/800/145/final, downloaded: [August, 12th 2023]

[22] Mohammed, M., & Abed, F. (2020). A symmetric-based framework for securing cloud data at rest. *Turkish Journal of Electrical Engineering and Computer Sciences*, 28(1), 347-361.

[23] Moher, D., Liberati, A., Tetzlaff, J., Altman, D. G., & PRISMA Group*. (2009). Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. *Annals of internal medicine*, *151*(4), 264-269.

[24] National Institute of Standards and Technology (2023) The NIST Cybersecurity Framework 2.0. (National Institute of Standards and Technology, Gaithersburg, MD),

NIST Cybersecurity White Paper (CSWP) NIST CSWP 29 ipd. https://doi.org/10.6028/NIST.CSWP.29.ipd

[25] Nithya, S. M. V., & Rhymend Uthariaraj, V. (2021). Identity-based Provable Data Possession for Multicloud Storage with Parallel Key-Insulation. *KSII Transactions on Internet and Information Systems (TIIS)*, 15(9), 3322-3347.

[26] Pinheiro, A., Dias Canedo, E., de Sousa Junior, R. T., de Oliveira Albuquerque, R., García Villalba, L. J., & Kim, T. H. (2018). Security architecture and protocol for trust verifications regarding the integrity of files stored in cloud services. *Sensors*, 18(3), 753.

[27] Rauthan, J. S., & Vaisla, K. S. (2021). Vrs-db: Preserve confidentiality of users' data using encryption approach. *Digital Communications and Networks*, 7(1), 62-71.

[28] Statista (2022). Cloud-based data storage or backup usage intentions in companies worldwide as of 2019, https://www.statista.com/statistics/1114013/worldwide-cloud-usage-for-data-storage-or-backup/#statisticContainer, downloaded: [June, 31th 2023]

[29] Tian, J., & Wang, Z. (2020). Fine-grained assured data deletion scheme based on attribute association. *Computers & Security*, 96, 101936.

[30] Uddin, M., Khalique, A., Jumani, A. K., Ullah, S. S., & Hussain, S. (2021). Next-generation blockchain-enabled virtualized cloud security solutions: review and open challenges. *Electronics*, 10(20), 2493.

[31] United Nations Conference on Trade and Development [UNCTAD] (2021). *Digital Economy Report 2021: Cross-Border Data Flows and Development: For Whom the Data Flow*. United Nations publication. Sales No. E.21.II.D.18. New York and Geneva.

[32] United Nations Conference on Trade and Development [UNCTAD] (2019). *Digital Economy Report 2019: Value Creation and Capture: Implications for Developing Countries*. United Nations publication. Sales No. E.19.II.D.17. New York and Geneva.

[33] Vo, V., Yuan, X., Sun, S., Liu, J. K., Nepal, S., & Wang, C. (2021). Shielddb: An encrypted document database with padding countermeasures. *IEEE Transactions on Knowledge and Data Engineering*.

[34] Wu, T., Yang, G., Mu, Y., Guo, F., & Deng, R. H. (2019). Privacy-preserving proof of storage for the pay-as-you-go business model. *IEEE Transactions on Dependable and Secure Computing*, 18(2), 563-575.

[35] Yadav, A. K., Ritika, M. L. G., & Garg, M. L. (2019). Monitoring Based Security Approach for Cloud Computing. *Ingénierie des Systèmes d Inf.,* 24(6), 611-617.

[36] Yan, H., Liu, Y., Zhang, Z., Wang, Q. (2021). Efficient privacy-preserving certificateless public auditing of data in cloud storage. *Security and Communication Networks*, 2021, 1-11.

[37] Zhang, J., Wang, B., Wang, X. A., Wang, H., & Xiao, S. (2020). New group user based privacy preserving cloud auditing protocol. *Future Generation Computer Systems*,106, 585-594.

[38] Zhang, P., Gao, J., Jia, W., & Li, X. (2019). Design of compressed sensing fault-tolerant encryption scheme for key sharing in IoT Multi-cloudy environment (s). *Journal of Information Security and Applications*, 47, 65-77.

[39] Zheng, F., Peng, X., & Li, Z. (2022). An efficient User's attribute revocation scheme suitable for data outsourcing in cloud storage. *Wireless Communications and Mobile Computing*, 2022.

Review article / Pregledni rad

ELEKTRODERMALNA AKTIVNOST U ISTRAŽIVANJIMA U TURIZMU – BIBLIOMETRIJSKA ANALIZA

IVANA PAVLIĆ
Sveučilište u Dubrovniku
Odjel za ekonomiju i poslovnu ekonomiju
Lapadska obala 7, 20000 Dubrovnik, Hrvatska
ipavlic@unidu.hr

SAŽETAK

Elektrodermalna aktivnost, ranije poznata i kao galvanski odgovor kože predstavlja jedan od osjetljivijih psihofizioloških indikatora emocionalne i kognitivne uzbuđenosti. Upravo iz toga razloga koristi se kao objektivna mjera nepristranog emocionalnog uzbuđenja pojedinca. Mjerenje elektrodermalne aktivnosti se primjenjuje u znanstvenim istraživanjima u raznim područjima. Prema tome, osnovna svrha ovoga rada je istražiti dosadašnju primjenu mjerenja elektrodermalne aktivnosti u istraživanjima u turizmu primjenom bibliometrijske analize. Obuhvaćena su 23 rada iz Web of science (WoS) online baze podataka od 1994. kada je, uz mjerenje otkucaja srca i krvnoga tlaka, prvi put primijenjena tehnika elektrodermalne aktivnosti za mjerenje psihofizioloških reakcija izazvanih sjećanjima na iskustva rekreacije na otvorenom, pa sve do danas - 2023. Podatci provedene analize su obrađeni, a bibliografski prikazi izrađeni pomoću Visualisation of Similarities (VoS) programa. Rad je baziran na analizi postojeće literature koja se bavi primjenom mjerenja elektrodermalne aktivnosti u turizmu i ugostiteljstvu, istraživanju vrste radova, autora i zemalja koje su se bavile ovom problematikom, a ostvarili su najveći doprinos u ovom području. Analizirali su se najcitiraniji članci, godišnji broj publikacija, ključne riječi, kocitiranja autora i časopisa te bibliografsko povezivanje zemalja i autora. Rezultati provedene bibliometrijske analize ukazuju na nedovoljnu primjenu mjerenja elektrodermalne aktivnosti u istraživanjima u turizmu uzimajući u obzir prednosti ove tehnike i rezultate koje u kombinaciji s drugim neuroznanstvenim metodama može imati.

KLJUČNE RIJEČI: elektrodermalna aktivnost, emocije, istraživanje, turizam, bibliometrijska analiza

ELECTRODERMAL ACTIVITY IN TOURISM RESEARCH – BIBLIOMETRIC ANALYSIS

ABSTRACT

Electrodermal activity, formerly known as the galvanic skin, represents one of the most sensitive physio-psychological indicators of emotional and cognitive arousal. It is precisely for this reason that it is used as an objective measure of an individual's unbiased emotional arousal. Measurement of electrodermal activity is applied by scientific research in various fields. Therefore, the main purpose of this paper is to research the current application of electrodermal activity measurement in tourism research. 23 papers from the Web of Science (WoS) online database are included since 1994, when, in addition to measuring heart rate and blood pressure, the electrodermal activity technique was first applied to measure psychophysiological reactions associated with memories of outdoor recreation experiences, up to today - 2023. The data of the conducted analysis were processed, and bibliographic presentations were created using the Visualization of Similarities (VoS) program. The work is based on the analysis of existing literature that deals with the application of electrodermal activity measurement in tourism and catering, research of the types of works, authors and countries that dealt with this issue and made the greatest contribution in this area. The most cited articles, annual number of publications, keywords, co-citations of authors and journals, and bibliographic linking of countries and authors were analysed. The results of the bibliometric analysis indicate insufficient application of electrodermal activity measurement in tourism research, considering the advantages of this technique and the results it can have in combination with other neuroscientific methods.

KEYWORDS: electodermal activity, emotions, research, tourism, bibliometric analyisis

1. UVOD

Mjerenje elektrodermalne aktivnosti se primjenjuje za ispitivanje implicitnih emocionalnih stanja koja nisu pod utjecajem svijesti pojedinca. U bihevioralnim istraživanjima mjerenje elektrodermalne aktivnosti počelo se primjenjivati krajem osamdesetih godina dvadesetog stoljeća, međutim u posljednjem desetljeću, primjena ove tehnike u mjerenju emocionalne uzbuđenosti potrošača je sve učestalija, prvenstveno radi dostupnosti opreme. Sva veća primjena neuroznanstvenih tehnika dovela je do napretka i u istraživanju ponašanja potrošača u turizmu u posljednjem desetljeću.

Elektrodermalna aktivnost kože (EDA) je električno svojstvo ljudske kože koje je ovisno o aktivnostima simpatičkog dijela autonomnog živčanog sustava svakog pojedinca. Mijenja se ovisno o psihološkom stanju osobe, što je prvenstveno rezultat kognitivnih i mentalnih zadataka koje osoba obavlja. Danas se EDA sve više koristi u raznim znanstvenim područjima, kao rezultat sve veće zainteresiranosti istraživačkih institucija za objektivne informacije o ljudskoj percepciji proizvoda (Geršak, 2020). Signal elektrodermalne aktivnosti je indikator pobuđenosti simpatičkog živčanog sustava i može opisivati stupanj uzbuđenosti ili anksioznosti osoba, kao i promjene uzbuđenosti povezane s raznim osjećajima. Najčešće promatrano svojstvo elektrodermalne aktivnosti i jedan od najčešće korištenih fizioloških parametara u psihofiziologiji je vodljivost kože (engl. Skin conductance-SC). Zbog svoje jednostavne

primjene, cjenovno prihvatljivih mjernih instrumenata i razumne korelacije s aktivnošću autonomnog živčanog sustava, koristi se u mnogim psihofiziološkim istraživanjima pa tako i u turizmu i ugostiteljstvu. Nastavno na prethodno, svrha ovoga rada biblometrijskom analizom utvrditi primjenjuje li se u istraživanjima u turizmu mjerenje elektrodermalne aktivnosti, gdje se najviše primjenjuje i jesu li radovi na ovu problematiku izazvali određeni interes među znanstvenicima iz područja turizma.

2. PREGLED LITERATURE

2.1. ELEKTRODERMALNA AKTIVNOST KOŽE

Brojni su autori u prošlosti istraživali EDA i poistovjetili je s vodljivošću kože (SC), galvanskim odgovorom kože (GSR), elektrodermalnim odgovorom (EDR), psihogalvanskim refleksom (PGR), razinom vodljivosti kože (SCL), odgovorom vodljivosti kože (SCR) i simpatičkim odgovorom kože (SSR) (Kołodziej, 2019). Primjena elektrodermalne analize se smatra jednim od najučinkovitijih alata za procjenu emocionalnog uzbuđenja s obzirom da vodljivost kože visoko reagira na različite psihološke podražaje (Gangadharbatla i sur., 2013.). Kada su pojedinci izloženi podražaju, aktivira se njihov autonomni živčani sustav. Taj proces dovodi do aktivnosti žlijezda znojnica, a time i do promjene vodljivosti kože (Grabe i sur., 2000.). Primjena mjerenja elektrodermalne aktivnosti u istraživanjima nije usmjerena samo na sirovi signal, nego na njegove komponente i to na njegovu faznu komponentu koja je definirana u suprotnosti s drugom toničnom komponentom. Tonička komponenta se odnosi na razinu vodljivosti kože koja je povezana sa sporim, prirodnim pomacima elektrodermalne aktivnosti i koristi se za procjenu odgovora pojedinca na tonički podražaj (Boucsein et al., 2012.).

Razina vodljivosti kože je apsolutna razina vodljivosti na koju utječu prirodne varijacije zbog regulacije tjelesne homeostaze kao što je temperatura na primjer, razina vodljivosti kože općenito je niska tijekom spavanja i visoka dok je osoba budna ili aktivna (Dawson et al., 2017.). Fazna komponenta ili reakcija vodljivosti kože osjetljiva je na novost, intenzitet i značaj podražaja. Zbog određenog događaja ili podražaja (npr. glasna buka), reakcija vodljivosti kože dogodit će se u obliku brzog povećanja vidljivog u dermalnoj aktivnosti (Braithwaite et al., 2013.). U skladu s dimenzionalnom teorijom emocija, emocija se sastoji od najmanje dvije dimenzije: valencije i uzbuđenja. Valencija se fokusira na osjećaj zadovoljstva ili pozitivnosti, dok je uzbuđenje razina stimulacije ili intenzitet hedonistički izražene vrijednosti (Bigné & Andreu, 2004.). Nedavno istraživanje pokazalo je da je emocionalno uzbuđenje značajan psihološki mehanizam koji podupire motivaciju za putovanje (Güzel i sur., 2020), nezaboravno turističko iskustvo (Şahin i Güzel, 2020) i ponašanje turista (Su et al., 2020). Ova spoznaja nije iznenađujuća s obzirom na to da teorija uzbuđenja ili teorija aktivacije u psihologiji sugeriraju da specifično okruženje, poput atmosfere turističke destinacije ili doživljaja, može potaknuti uzbuđenje, koje zauzvrat utječe na ponašanje (Picard et al., 2016). Međutim, Tuerlan et al. (2021) su u sustavnom pregledu literature o istraživanju emocija u kategorijama turizma i ugostiteljstva utvrdili da je većina prethodnih studija otkrila da je utvrđivanje i mjerenje učinka emocionalnog uzbuđenja zahtjevno i da su se analizirane studije većinom usredotočile na ispitivanje emocija na temelju njihove valencije dok zanemaruje druge dimenzije emocija, kao što je uzbuđenje. Jedno od mogućih objašnjenja je činjenica da je uzbuđenje u velikoj mjeri subjektivan i nesvjestan proces, pa ga je stoga teško precizno utvrditi primjenom samo tradicionalnih metoda istraživanja ponašanja potrošača.

U turizmu, dominantne mjere emocionalnog uzbuđenja temelje se na upitnicima koje ispitanici sami procjenjuju, kao što je 'zadovoljstvo—ljestvica uzbuđenja-dominacije (Bigné & Andreu, 2004.). Međutim, dovodi se u pitanje pouzdanost tih mjera u kojima ispitanici - subjektivno bilježe emocionalne reakcije, zasebno dimenzije emocija (npr. uzbuđenje) između ostaloga i u turizmu s obzirom na to da turisti možda nisu svjesni ili se nedovoljno sjećaju svojih emocionalnih iskustava koja su obično nesvjesna i prolazna (Tuerlan et al., 2021). Kako bi se unaprijedilo razumijevanje značenja uloge istraživanja emocija u turizmu, javlja se sve veća potreba za primjenom neuroznanstvenih ili psihofizioloških metoda koje omogućuju mjerenje određenih emocionalnih dimenzija u izolaciji. Dosadašnja istraživanja iz psihologije utvrdila su pozitivnu korelaciju između emocionalnog uzbuđenja i elektrodermalne aktivnosti s empirijskim dokazima (Bradley & Lang, 1999.). Stoga sve više znanstvenika u različitim područjima primjenjuju mjerenje elektrodermalne aktivnosti kao izuzetno pouzdanu tehniku za bilježenje kontinuiranog i nepristranog emocionalnog uzbuđenja posjetitelja u turizmu (Hadinejad et al., 2019; Li et al., 2018; Mitas et al., 2022).

2.2. PRIMJENA BIBLIOMETRIJSKE ANALIZE U TURIZMU

Bibliometrijska analiza predstavlja kvantitativni, sustavni pregled znanstvene literature s ciljem procjene znanstvenog napretka određenog područja istraživanja (Ruhanen et al., 2015). Znanstveno je računalno potpomognuta metoda koja identificira temeljna područja istraživanja ili autore i njihov međusobni odnos, stavljajući u suodnos sve publikacije povezane s određenom temom istraživanja (de Bellis, 2009). Primjena bibliometrijske analize omogućuje znanstvenicima istraživanje elemenata istraživanja, trendova u određenim područjima, intelektualnih struktura istraživačke domene, uspješnosti časopisa i članaka te obrazaca suradnje (de Bruyn et al., 2023). Bibliometrijska analiza se primjenjuje kao posebna metoda analize velikog broja znanstvenih podataka u različitim u različitim područjima istraživanja pa tako i u turizmu. U razdoblju od 2005. do 2023. prema podatcima Clarivate Web of Science objavljeno je 300 znanstvenih radova sa 3.909 ukupnog broja citata (3.662 bez osobnog citiranja) i 41 H indeksom. Radovi se objavljuju u različitim dijelovima Svijeta, a najviše je izdano u Kini (20%), Španjolskoj (19%), SAD-u (15%), Indiji (11%), Turskoj (10,3%), Portugalu (7,7%), Engleskoj (7,3%), Australiji (7%)i Brazilu (6,3%). Može se zaključiti da znanstveni radovi koji primjenjuju bibliometrijsku analizu u području turizma dobivaju sve veće značenje.

Palmer et al., (2005) su ispitivali primjenu statističkih metoda u turizmu od 1998. do 2002. pri čemu su analizirali 1790 članaka. Benckendorff (2009) je analizirao znanstvene radove australskih i novozenlandskih istraživača u časopisima Annals of Tourism research i Tourism Management od 1994. do 2007. Hall (2011) je istaknuo važnost primjene bibliometrijske analize radova koji su istraživali kvalitetu u turizmu. Ye et al. [20] su ispitivali različite akademske suradnje nekoliko časopisa koji se odnose na hotelijerstvo i turizam od 1991. do 2010. koristeći bibliometrijsku analizu. Ruhanen et al. (2015) su istraživali trendove i modele istraživanja održivog turizma u razdoblju od 25 godina u četiri najbolje rangirana časopisa iz područja turizma. Figueroa et al. (2015) su nastojali potaknuti raspravu o funkcioniranju istraživanja u turizmu kao sustava za generiranje znanja kroz kritički prikaz potpodručja rodnog istraživanja u turizmu 466 radova časopisa objavljenih od 1985. do 2012. Omerzel (2016) je primijenila bilbiometrijsku analizu u istraživanju inovacija u turizmu. Analiza je obuhvatila 152 rada. Güzeller i Çeliker, (2018) su analizirali 4.473 rada objavljena između 2007. i 2016., a nastojali su ispitati sličnosti i razlike u trendovima turskih i drugih međunarodnih publikacija u turizmu. Johnson i Samakovlis, (2019) su istraživali radove o pametnom turizmu u razdoblju od 2000. do 2018.: Shahbaz et al. (2021). analizirali radove koji se bave turizmom i njegovim

utjecajem na degradaciju okoliša korištenjem bibliometrije, analizirajući članke s Web of Science objavljene između 1999. i 2020. Usredotočujući se na ekonomiju dijeljenja i turizam, Mody et al. (2021) su primjenom bibliometrijske analize objavili kritički pregled istraživanja objavljenih u turizmu između 2010. i 2020. Atabay i Güzel (2021) su bibliometrijskom analizom istražili primjenu neuroznastvene tehnike praćenja kretanja očiju u istraživanjima u turizmu. Analizirali su 64 rada i to u razdoblju odn 2013. do 2019. Sousa et al. (2022) su analizirali primjenu virtualne stvarnosti u istraživanjima u turizmu i utvrdili su da je unatoč prednostima, primjena VR tehnike u turizmu je jako mala. Knani et al. (2022) su analizirali primjenu umjetne inteligencije u turizmu i ugostiteljstvu od 1984. do 2021.

3. METODOLOGIJA

Osnovna svrha ovoga rada je dati detaljan pregled literature koja se bavila primjenom elektrodermalne analize u turizmu koristeći bibliometrijsku analizu. Podaci za bibliometriju se mogu dobiti iz baza podataka kao što je Scopus. Bibliometrijsku analizu o raznim temama istraživanja u turizmu su primijenili sljedeći znanstvenici: Hall, 2011; Chim-Miki & Batista-Canino, 2017; Mulet-Forteza et al., 2018; Rama, 2019; Sharma & Rao, 2019; Miskiewicz, 2020; Padrón Ávila & Hernández-Martín, 2020; Atabay i Güzel, 2021; Soliman et al. , 2021; Rathi, 2022; Toker, & Oktay, 2023. Osim Scopus baze podataka, bibliometrijska analiza o istraživanjima u turizmu se može realizirati i preko Web of Science (WoS) baze podataka (Barrios et al., 2008; Muñoz-Leiva , 2017; Yuan, 2018; Su et al., 2019; Merigó et al., 2019; Mavric et al., 2021; Hocevar & Bartol, 2021; Dimitrovski 2021; Guanghui et al., 2021; Atsız et al., 2022; Şimşek & Kalıpçı, 2022; Liu et al., 2022; Fauzi, 2023; Dinç et al., 2023; Ercan, 2023). Treća skupina autora kombinira ove dvije baze podataka u primjeni bibliometrijske analize (Durán-Sánchez, 2017; Batista Sánchez, et al. 2022; Shekhar & Valeri, 2022; Kabil et al., 2022; Rojas-Lamorena et al., 2022; Bernardo, E., et al, 2023; Gulyas & Molnar, 2023). Za potrebe izrade ovoga rada baza podataka WoS smatrala se prikladnom iz nekoliko razloga. Prvo, cilj je bio smanjiti mogućnost ponavljanja analize istih studija jer neki članak može biti i u Scopus i u WoS bazi i to može proći neprimijećeno (Mavric et al., 2021.). Osim toga, WOS je citantna i bibliografksa baza podataka koja ima tri indeksa koji pokrivaju preko 18.500 časopisa i prati izdanja s najvišim impakt faktorima i sa citantnom analizom te je jedna od svjetskih vodećih relevantnih baza podataka (Merigó et al., 2015; Liu et al., 2022; Fauzi, 2023; Dinç et al., 2023) Treće, u WoS bazi podataka postoji veliki broj bibliometrijskih analiza koju su proveli mnogi znanstvenici iz područja turizma.

U ovome radu u bibliometrijskoj analizi su primijenjeni podatci od 15. srpnja 2023. Kako bi se provela bibliometrijska analiza mjerenja elektrodermalne aktivnosti u istraživanjima u turizmu, iz baze su filtrirani dokumenti prema sljedećim kriterijima, članci objavljeni na engleskom jeziku, koji uključuju ključne riječi: „TURIZAM“ ILI „TURIST“ ILI „TURISTIČKA DESTINACIJA“ I „ELEKTRODERMALNA AKTIVNOST“ ILI „EDA“ ILI „GALVANSKI ODGOVOR KOŽE“ ILI „GALVANSKA REAKCIJA KOŽE“ ILI „GSR“ ILI „VODLJIVOST KOŽE“ ILI „SC“ ILI „TONIČNA FAZA“ ILI „FAZIČNA FAZA“ ILI „SCL“ ILI „SCR“ ILI „RAZINA VODLJIVOSTI KOŽE“ ILI „ODGOVOR VODLJIVOSTI KOŽE“. Pretraživanje je uključilo varijacije svih navedenih pojmova. Rezultati su ograničeni na članke objavljene na engleskom jeziku.

Prikaz 1. Faze izrade bibliometrijske analize primjene elektrodermalne aktivnosti u istraživanjima u turizmu

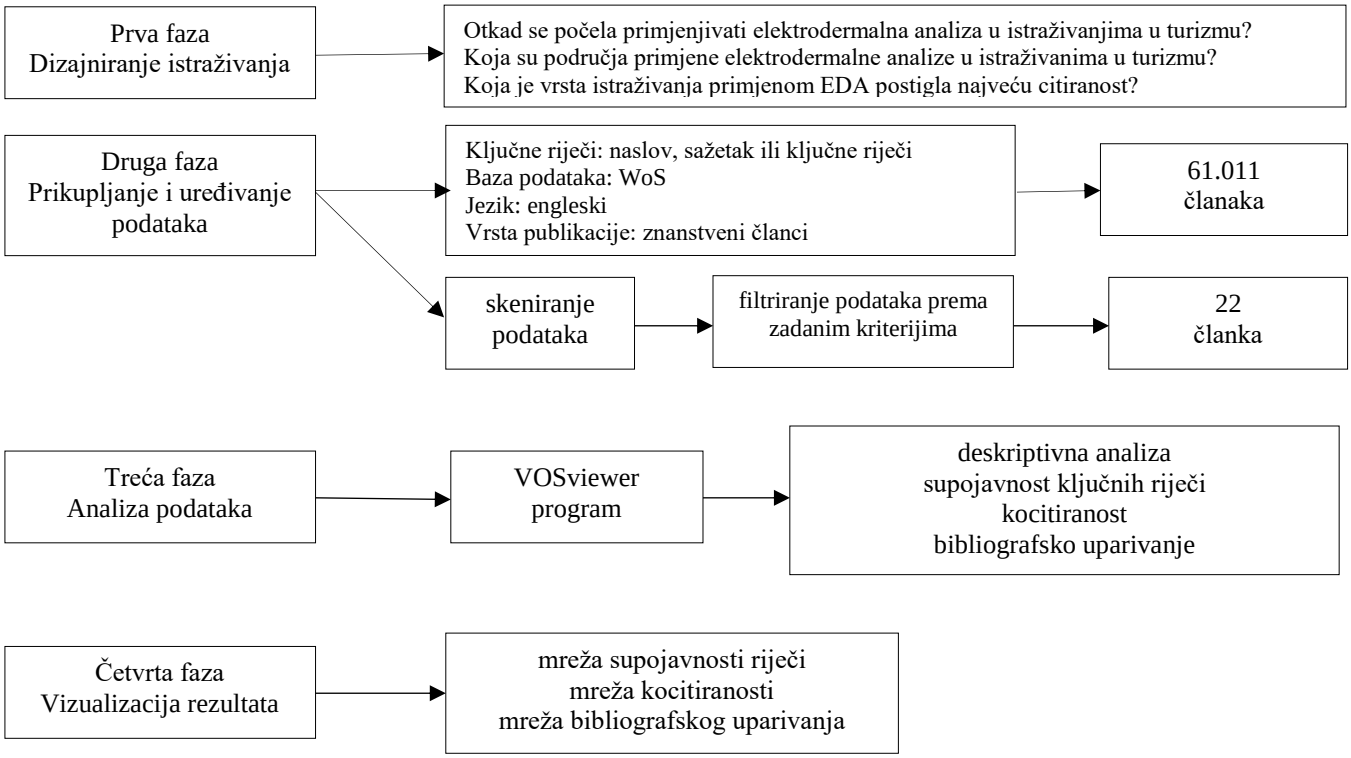

Izvor: Izrada autora

Prema navedenim kriterijima u cijeloj WOS bazi dobiveno je 61.011 radova u svim kategorijama, međutim analizom kategorije „ugostiteljstvo, slobodno vrijeme, sport i turizam“ filtrirano je 66 radova. Nakon filtracije dobivenih rezultata s definiranim kriterijem ugostiteljstva, turizma, dokolice eliminirana je kategorija sporta i radovi koji uključuje gore navedene ključne riječi – kratice koje ne podrazumijevaju analiziranu problematiku npr. „SCR“ pod kojim se analiziralo „Scale, change and resilience“, a ne „odgovor vodljivosti kože“ - „skin conduntance response“ ili u drugom slučaju „SCL“ pod kojim se analizirala skala lista simptoma „symptom checklist“, a ne „razina vodljivosti kože“ („skin conduntance level – SCL“), također je bio slučaj i kratice „EDA“ koja je uključila nekoliko radova s ključnom riječi „ekonomska razvojna agencija“ („economic development agency“ – EDA, a ne „elekrodermalnu aktivnost“), dobivena su 22 dokumenta koja su proslijeđena u daljnju analizu. Analiza filtriranih dokumenata realizirana je bibliometrijskim mapiranjem u programu VOSviewer. Primijenjena je deskriptivna analiza, analiza supojavnosti ključnih riječi, analiza kocitiranosti te analiza bibliografskog uparivanja (Prikaz 1.).

4. REZULTATI ISTRAŽIVANJA

U WoS bazi, nakon druge faze analize, filtrirana su 22 rada koja se bave primjenom elektrodermalne analize u istraživanjima u području turizma u kategoriji „ugostiteljstvo, slobodno vrijeme, sport i turizam“. Prvi rad je objavljen 1994. godine. Od tada do danas, citiran je 561 rad na ovu temu, ukupne citiranost 824 (728 bez osobne citiranosti) od 35,83 po radu i H-indeksom 13.

Distribucija broja objavljenih radova kao i broja citata te ukupnog broja citata u razdoblju od 1994. godine, grafički je prikazana na Prikazu 2. Prvi rad pod naslovom „Recollections of Outdoor Recreation Experiences - A Psychophysiological Perspective“ je objavljen 1994. godine. Provedeno je laboratorijsko istraživanje za identificiranje psihofizioloških odgovora koje su povezane sa sjećanjima na doživljena iskustva na otvorenome. Analiziran je krvni tlak, otkucaji srca i elektrodermalna aktivnost kože. Njegova citiranost je evidentirana 1996. Najveći broj radova analiziran problematike je objavljen 2020. godine (pet radova).

Prikaz 2. Distribucija broja objavljenih radova i citiranosti po godinama

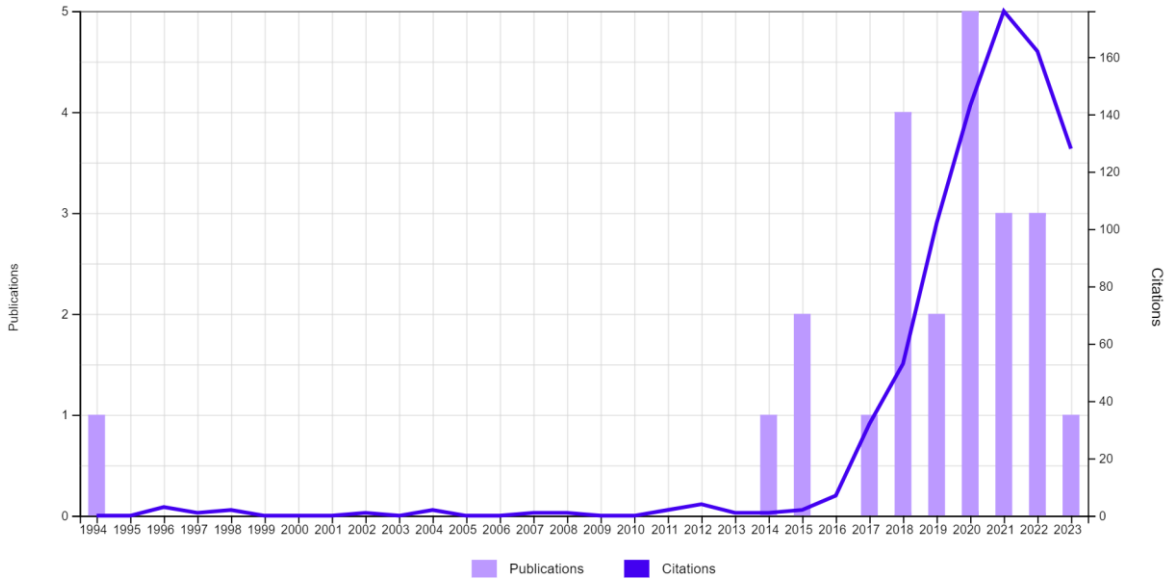

Izvor: Clarivate Web of Science, Copyright Clarivate 2023.

Najviša razina citiranosti ostvarena je 2021. godine. Najcitiraniji rad pod naslovom „Measuring Emotions in Real Time: Implications for Tourism Experience Design“ autori Kim i Fesenmajer objavljen je 2015. godine. Njegova citiranost je 181 (prosjek po godini je 20,11). Rad je analizirao reakcije turista u prirodnom okruženju primjenom elektrodermalne analize na dvoje putnika u Philadelfiji (SAD). Li et al. (2016) su analizirali primjenu psihofizioloških mjera u turizmu, a poseban naglasak su stavili na istraživanje prednosti primjene analize vodljivosti kože i elektromiografije lica u praćenju emocionalnih reakcija na oglase turističke destinacije. Trideset i troje sudionika bilo je izloženo trima oglasima destinacije. Babakhani et al. (2017) su analizirali učinkovitost marketinških komunikacijskih poruka primjenom psihofizioloških alata i mjerenjem stavova. Shoval et al. (2018) su primijenili suvremene metode pomoću kojih su prostorno-vremenske podatke kombinirali s fiziološkim mjerama emocija i semantičkim kontekstualnim informacijama da bi dobili sveobuhvatno i integrativno razumijevanje iskustva turista u vremenu i prostoru na uzorku od 68 turista u Jeruzalemu. Hadinejad et al. (2019) uspoređuju psihofiziološke metode i metode samoprocjene za utvrđivanje emocionalnih odgovora na marketinške podražaje u turizmu u kojima se manipuliralo glazbom na 37 sudionika koristeći četiri ključne tehnike *FaceReader*™, vodljivost kože, ankete o samoprocjeni i post hoc intervjue (Tablica 1.).

Tablica 1. Najcitiraniji radovi u WoS bazi na temu primjene elektrodermalne aktivnosti u istraživanjima u turizmu

	Autori	**Naslov rada**	**Naziv časopisa**	**God.**	**WoS citati**
1.	Kim, J. & Fesenmaier, D.	Measuring Emotions in Real Time: Implications for Tourism Experience Design	Journal Of Travel Reserach	2015	181
2.	Li, S. S.; Scott, N & Walters, G	Current and potential methods for measuring emotion in tourism experiences: a review	Current Issues In Tourism	2015	138
3.	Shoval, N.; Schvimer, Y. & Tamir, M.	Real-Time Measurement of Tourists' Objective and Subjective Emotions in Time and Space	Journal Of Travel Research	2018	90
4.	Li, S.S.; Walters, G.; (...); Scott, N.	Using skin conductance and facial electromyography to measure emotional responses to tourism advertising	Current Issues In Tourism	2018	76
5.	Kim, S.B.; Kim, D.Y. & Bolls, P.	Tourist mental-imagery processing: Attention and arousal	Annals Of Tourism Research	2014	75
6.	Li, S.S.; Walters, G.; (...); Scott, N.	A Comparative Analysis of Self-Report and Psychophysiological Measures of Emotion in the Context of Tourism Advertising	Journal Of Travel Research	2018	48
7.	Babakhani, N.; Ritchie, B.W. and Dolnicar, S.	Improving carbon offsetting appeals in online airplane ticket purchasing: testing new messages, and using new test methods	Journal Of Sustainable Tourism	2017	39
8.	Tarrant, M.; Manfredo, M. & Driver, B.	Recollections of Outdoor Recreation Experiences - A Psychophysiological Perspective	Journal Of Travel Research	1994	26
9.	Hadinejad, A.; Moyle, B.D.; (...); Scott, N.	Physiological and self-report methods to the measurement of emotion in tourism	Tourism Recreation Research	2019	23

Izvor: Clarivate Web of Science, Copyright Clarivate 2023.

Sljedeća tablica prikazuje vrste radova koji su objavljeni u WoS bazi na ovu temu. Najviše je članaka i preglednih članaka dok je od ukupno 22 rada jedan rad objavljen kao poglavlje u knjizi.

Tablica 2. Vrsta radova objavljenih u WoS bazi na temu primjene elektrodermalne aktivnosti u istraživanjima u turizmu

Vrsta rada	**Broj radova**	**%**
Članak	19	86,364
Pregledni članak	2	9,091
Poglavlje u knjizi	1	4,545

Izvor: Clarivate Web of Science, Copyright Clarivate 2023.

WoS baza se sastoji od 252 tematske kategorije koje su raspoređene u opću kategoriju znanosti općenito (*Science Citation Indeks*), u kategoriju društvenih znanosti (*Social Science Citation Indeks*) i u kategoriju umjetnosti i humanističkih znanosti (*Arts & Humanities Citation Indeks*). Sljedeća tablica je izrađena dodjeljivanjem svakog pojedinačnog časopisa jednoj ili više predmetnih kategorija. Osim bazne kategorije „ugostiteljstvo, slobodno vrijeme, sport i turizam“ radovi na temu primjene elektrodermalne aktivnosti u istraživanjima u turizmu

objavljeni su u časopisima koji su dodijeljeni još i u kategoriju „sociologije“, „menadžmenta“, „poslovanja“, „kulture“ i „zelene održive znanstvene tehnologije“.

Tablica 3. Vrsta radova objavljenih u WoS bazi na temu primjene elektrodermalne aktivnosti u istraživanjima u turizmu

Kategorije Web of Science	**Broj radova**	**%**
Ugostiteljstvo, slobodno vrijeme, sport i turizam	22	100,000
Sociologija	5	21,739
Menadžment	4	17,391
Poslovanje	2	8,696
Kultura	1	4,348
Zelena održiva znanstvena tehnologija	1	4,348

Izvor: Clarivate Web of Science, Copyright Clarivate 2023.

Tablica 4. prikazuje pregled objavljenih radova na temu primjene mjerenja elektrodermalne aktivnosti u istraživanjima u turizmu po državama. Na prvom mjestu po zastupljenosti radova u ovom znanstvenom području je NR Kina s udjelom od 30,435%. Potom su tri zemlje (Australija, Nizozemska i SAD) s podjednakim brojem radova i zastupljenošću od 26,087% u ukupnom broju objavljenih radova.

Tablica 4. Pregled objavljenih radova na temu primjene elektrodermalne aktivnosti u istraživanjima u turizmu po državama

Zemlje	**Broj radova**	**%**
Narodna Republika Kina	7	30,435
Australia	6	26,087
Nizozemska	6	26,087
SAD	6	26,087
Engleska	2	8,696
Izrael	1	4,348
Meksiko	1	4,348
Švedska	1	4,348
Turska	1	4,348

Izvor: Clarivate Web of Science, Copyright Clarivate 2023.

Analizirani radovi su dosegli najveću razinu citiranosti (343 citata) u kategoriji „ugostiteljstvo, slobodno vrijeme, sport i turizam“, potom u kategoriji „menadžmenta“ 85 citata, potom u kategoriji „studije zaštite okoliša“ 51 citat, u „poslovanju 50 citata te u kategoriji „sociologija“ 39 citata. Citati iz ovoga područja se još javljaju u kategorijama zaštite okoliša, elektroničkog i računalnog inženjerstva, psihologije geografije itd. (Tablica 5.)

Tablica 5. Citiranost radova na temu primjene elektrodermalne aktivnosti u istraživanjima u turizmu prema WoS kategorijama

Web of Science kategorije	**Broj citata**	**%**
Ugostiteljstvo, slobodno vrijeme, sport i turizam	343	61,470
Menadžment	85	15,233
Studije zaštite okoliša	51	9,140

Poslovanje	50	8,961
Sociologija	39	6,989
Zelena održiva znanstvena tehnologija	27	4,839
Znanost o okolišu	24	4,301
Elektroničko i računalno inženjerstvo	21	3,763
Računalni informacijski sustavi	18	3,226
Psihologija	17	3,047
Računalne znanosti Interdisciplinarni pristup	13	2,330
Geografija	13	2,330

Izvor: Clarivate Web of Science, Copyright Clarivate 2023.

Ključne riječi u radovima na temu primjene elektrodermalne aktivnosti u istraživanjima u turizmu u WoS bazi podataka raspoređene su u 12 klastera (min jedna apojavnost). U prvi klaster spada 27 ključnih riječi, drugi klaster obuhvaća 24 ključne riječi, treći klaster obuhvaća 20 ključnih riječi, četvrti, peti i šesti 14 ključnih riječi, šesti, sedmi i osmi po 13 ključnih riječi, deveti 12, deseti obuhvaća deset ključnih riječi i jedanaesti i dvanaesti po devet ključnih riječi. Najučestalije ključne riječi koje se pojavljuju su „vodljivost kože“ („skin conduntance“) s 10 pojavnosti i ukupnom snagom veze od 111, zatim je ključna riječ „emocije“ sa razinom pojavnosti 7 i ukupnom snagom veze 70, slijedi ključna riječ „reakcije“ također sa razinom 7 pojavnosti i ukupnom snagom veze 98 te ključna riječ „elektrodermalna aktivnost“ s razinom pojavnosti 6 i ukupnom snagom veze od 79. U drugom slučaju analizirano je minimalno 3 pojavnosti ključnih riječi i dobilo se tri klastera. U prvom klasteru je osam riječi, u drugome šest, a u trećemu su četiri ključne riječi, a najčešća ključna riječ je kao i u prethodnom slučaju „vodljivost kože“ („skin conduntance“).

Prikaz 2. Supojavnost ključnih riječi

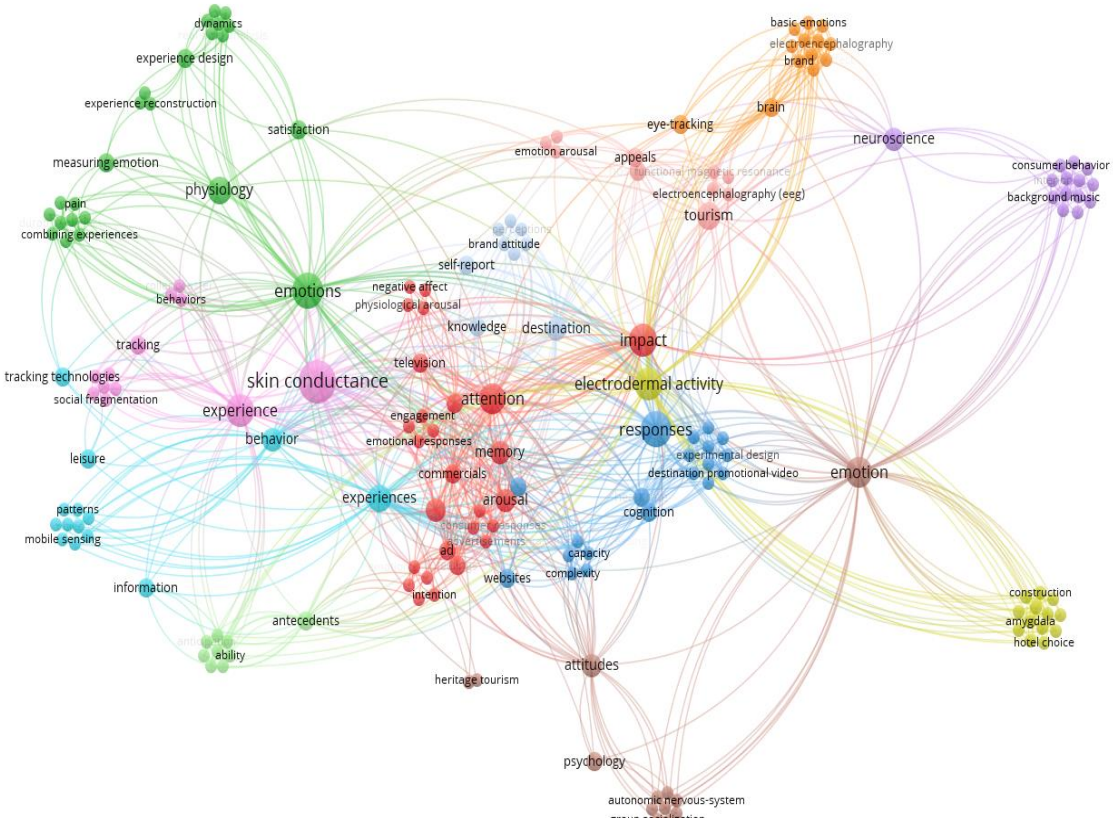

Izvor: Izrada autora u programu VOSviewer prema izvorima WoS baze podataka

Metoda kocitiranja autora koristi se u bibliometrijskim analizama kao značajna metoda za prepoznavanje intelektualne strukture istraživačkog područja. Primjenjuje se za određivanje učestalosti kojom se bilo koje istraživanje nekog autora citira zajedno s drugim autorom u referencama nekog drugog rada. Po ovoj metodi se utvrđuje sličnost dva citirana dokumenta. Snaga kocitiranja dva rada je veća što je veći broj dokumenata koji te radove citiraju skupa. Prema kocitiranosti autora, podijeljeni su autori u četiri klastera koji dijele sličnost predmeta istraživanja. U prvi klaster spada 48 autora, u drugi klaster spada 30 autora, u treći klaster spada 22 autora i u četvrti klaster spada 6 autora. Radove na temu primjene elektrodermalne analize u turizmu citiralo je 824 autora. Rad „Current and potential methods for measuring emotion in tourism experiences: a review“ autora Li et al. (2015.) ima zabilježene 43 citiranosti zajedno s nekim drugim autorima u referencama nekog drugog rada s ukupnom snage veze je 1.253 (Prikaz 3.).

Prikaz 3. Kocitiranost autora na temu primjene elektrodermalne aktivnosti u istraživanjima u turizmu

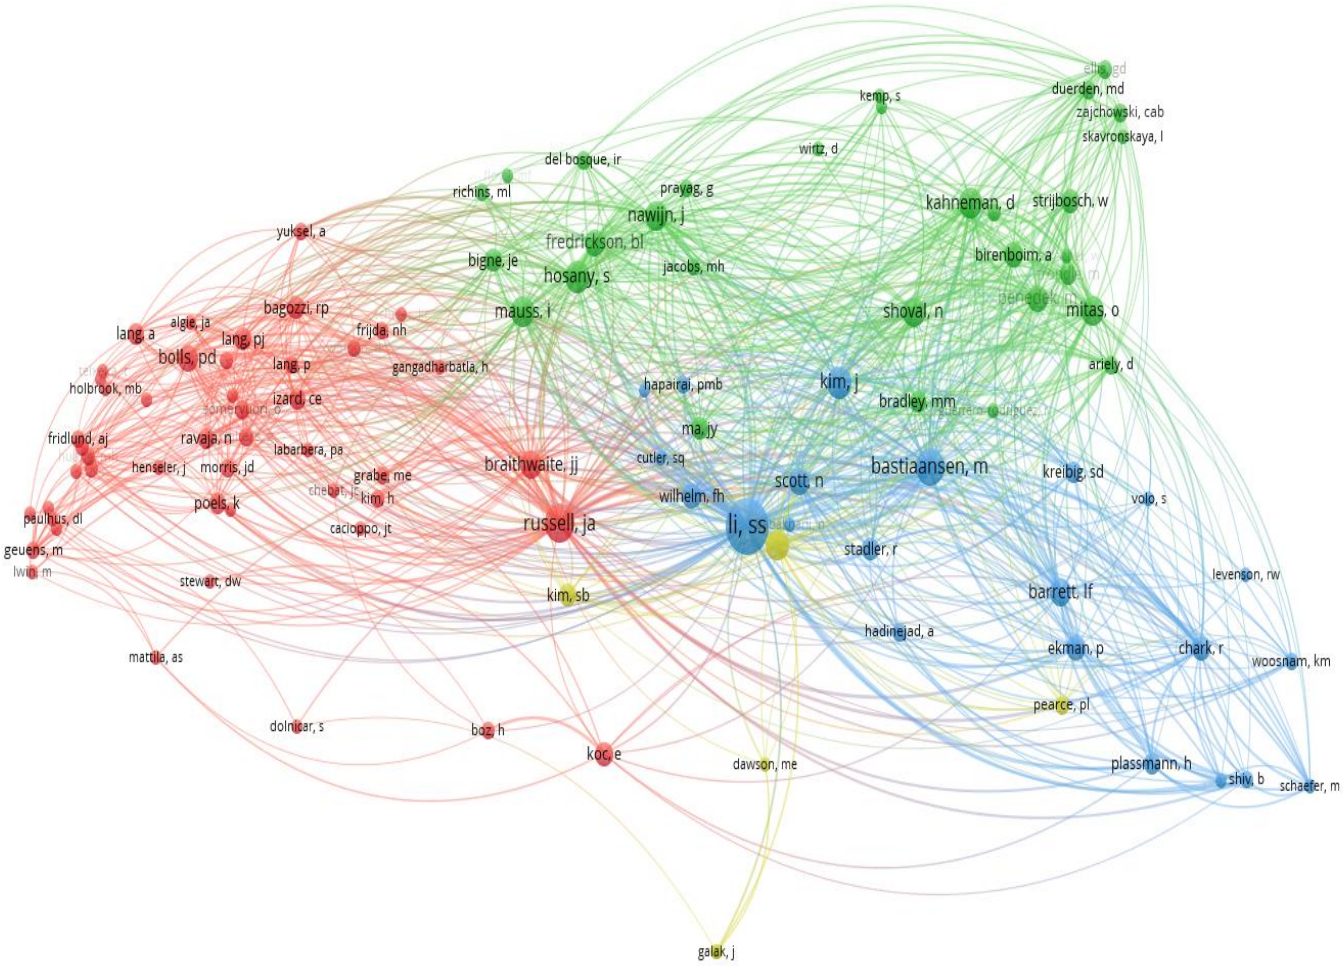

Izvor: Izrada autora u programu VOSviewer prema izvorima WoS baze podataka

Bibliografsko uparivanje se javlja kada dva rada ukazuju na zajednički treći rad u svojim bibliografijama. To je pokazatelj da postoji vjerojatnost da dva rada obrađuju sličnu temu. Dva su dokumenta bibliografski povezana ako oba citiraju jedan ili više zajedničkih dokumenata. Ova se metoda primjenjuje kao nadopuna analizi kocitiranja. Dok kocitiranje pokazuje da se dva rada pojavljuju zajedno u popisu literature drugog rada, bibliografsko uparivanje zbraja broj referenci koje grupa dokumenata ima zajedno. Prema ovoj metodi autori su raspoređeni u sedam klastera. U prvom klasteru je 18 autora, u drugom i trećem je devet autora, u četvrtom je sedam, u petom je šest autora, u šestom je pet autora i u sedmom su tri autora. Najjaču snagu veze bibliografskog uparivanja ima autor Bastaiaansen 5.159, Mitas 4.989 te Li 3.781 (Prikaz 4.).

Prikaz 4. Bibliografsko uparivanje autora na temu primjene elektrodermalne aktivnosti u istraživanjima u turizmu

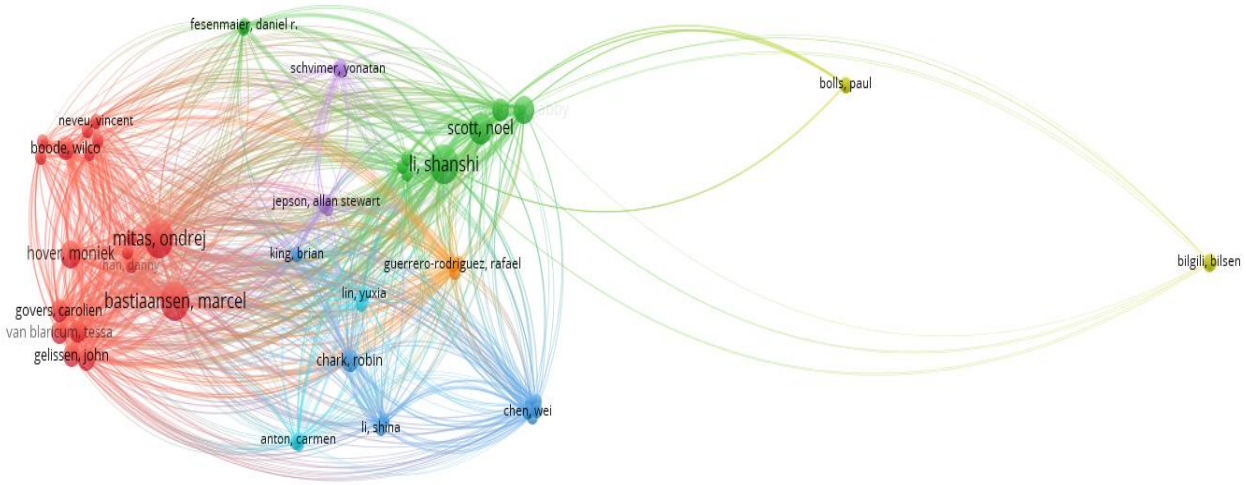

Izvor: Izrada autora u programu VOSviewer prema izvorima WoS baze podataka

5. ZAKLJUČAK

Mjerenje elektrodermalne aktivnosti se primjenjuje u znanstvenim istraživanjima kao objektivan indikator nepristranog emocionalnog uzbuđenja pojedinca. Koristi se za ispitivanje implicitnih emocionalnih stanja koja nisu pod utjecajem svijesti pojedinca što znači da na njih pojedinac nikako ne može utjecati. Primjena elektrodermalne analize se smatra jednim od najučinkovitijih alata za procjenu emocionalnog uzbuđenja s obzirom da vodljivost kože visoko reagira na različite psihološke podražaje. Upravo iz toga razloga se počela primjenjivati u istraživanju ponašanja potrošača uz tradicionalne metode istraživanja. Prvenstveno zbog svoje jednostavne primjene, cjenovno prihvatljivih mjernih instrumenata i razumne korelacije s aktivnošću autonomnog živčanog sustava, koristi se u mnogim psihofiziološkim istraživanjima pa i u turizmu i ugostiteljstvu od 1994. godine. U razdoblju od 1994. do danas u kategoriji ugostiteljstva, slobodnog vremena, sporta i turizma objavljeno je 66 radova koji su primijenili tehniku elektrodermalne aktivnosti da bi istražili nesvjesne reakcije na podražaje.

Iz područja turizma u razdoblju od 29 godina objavljeno je tek 22 rada iz kojih je u drugim radovima evidentirano 561 citat, ukupne citiranosti 824 sa H-indeksom 13. Prema vrsti radova

najviše je članaka i preglednih članaka. Ova tema se najviše obrađivala u NR Kini, Australiji, Nizozemskoj i SAD-u. Najviša razina citiranosti (343 citata) realizirana je u kategoriji "ugostiteljstvo, slobodno vrijeme, sport i turizam" te u kategoriji „menadžment" – 85 citata. Najučestalije ključne riječi koje se pojavljuju u radovima koji primjenjuju tehniku elektrodermalne analize u istraživanjima u turizmu su „vodljivost kože", „emocije", „reakcije" te „elektrodermalna aktivnost". Prema kocitiranosti autora, autori su podijeljeni četiri klastera koji dijele sličnost predmeta istraživanja, a autori Li et al. (2015.) imaju zabilježene 43 citiranosti zajedno s nekim drugim autorima u referencama nekog drugog rada s ukupnom snage veze je 1.253. Najjaču snagu veze bibliografskog uparivanja ima autor Bastaiaansen 5.159, Mitas 4.989 te Li 3.781.

Može se zaključiti da korištenje tehnike elektrodermalne aktivnosti u istraživanjima reakcija turista nije dovoljno prepoznata i primijenjena s obzirom na mogućnosti njene aplikacije i rezultata do kojih se može doći upotrebom ove tehnike. Provedena bibliometrijska analiza može biti od koristi znanstvenicima iz područja turizma koji se bave istraživanjem emocija za razumijevanje novih trendova i pristupa u istraživanju reakcija turista.

REFERENCE

[1] Atabay, E. & Güzeller, C. (2021). A Bibliometric Study on Eye-Tracking Research in Tourism. Tourism. 69. 595-610. 10.37741/t.69.4.8.

[2] Atsız, O., Öğretmenoğlu, M. & Akova, O. (2022). A bibliometric analysis of length of stay studies in tourism. European Journal of Tourism Research. 31. 3101. 10.54055/ejtr.v31i.2305.

[3] Babakhani, N., Ritchie, B. & Dolnicar, S. (2017). Improving Carbon Offsetting Appeals in Online Airplane Ticket Purchasing: Testing New Messages, and Using New Test Methods. Journal of Sustainable Tourism. 25. 10.1080/09669582.2016.1257013.

[4] Barrios, M., Borrego, A., Vilaginés, A., Ollé, C., & Somoza, M. (2008). A bibliometric study of psychological research on tourism. Scientometrics, 77(3), 453-467.

[5] Batista Sánchez, E., Deegan, J. & Pérez Ricardo, E. (2022). Influence of Internet On Tourism Consumer Behaviour: A Systematic Review. 10. 130-156. 10.30519/ahtr.917210.

[6] Benckendorff, P. (2009). Themes and Trends in Australian and New Zealand Tourism Research: A Social Network Analysis of Citations in Two Leading Journals (1994-2007). Journal of Hospitality and Tourism Management. 16. 1-15. 10.1375/jhtm.16.1.1.

[7] Bernardo, E., Sousa, N. & Kastenholz, E. (2023). Souvenirs in tourism studies: A bibliometric retrospective and future research agenda. 29. 249-264. 10.20867/thm.29.2.10.

[8] Bigné, J. E., & Andreu, L. (2004). Emotions in segmentation: An empirical study. Annals of Tourism Research, 31(3), 682–696.

[9] Boucsein, W., Fowles, D. C., Grimnes, S., Ben-Shakhar, G., Roth, W. T., Dawson, M. E., & Filion, D. L. (2012). Publication recommendations for electrodermal measurements. Psychophysiology, 49(8), 1017–1034.

[10] Bradley, M. M., & Lang, P. J. (1999). Measuring emotion: Behavior, feeling, and physiology. Cognitive Neuroscience of Emotion, 246–276.

[11] Braithwaite, J. J.,Watson, D. G., Jones, R., & Rowe, M. (2013). A guide for analysing electrodermal activity (EDA) & skin conductance responses (SCRs) for psychological experiments. Psychophysiology, 49, 1017–1034.

[12] Chim-Miki, A. F., & Batista-Canino, R. M. (2017). Tourism coopetition: An introduction to the subject and a research agenda. International Business Review, 26(6), 1208–1217. doi:10.1016/j.ibusrev.2017.05.003
[13] Clarivate Web of Science, Copyright Clarivate 2023. All rights reserved.
[14] Dawson, M., Schell, A., & Filion, D. (2017). The electrodermal system. In J. Cacioppo, L. Tassinary, & G. Berntson (Eds.), Handbook of Psychophysiology (Cambridge Handbooks in Psychology) (pp. 217–243). Cambridge: Cambridge University Press.
[15] de Bellis, N. (2009). Bibliometrics and citation analysis: from the science citation index to cybermetrics. scarecrow press.
[16] de Bruyn, C., Foued, B. S., Meyer, M. & Soliman, M. (2023). Research in tourism sustainability: A comprehensive bibliometric analysis from 1990 to 2022. Heliyon. 9. e18874. 10.1016/j.heliyon.2023.e18874.
[17] Dimitrovski, D., Lekovic, M. & Đurađević, M. (2021). The performativity of the tourism specialism knowledge network: sporting event economic impact assessment. Current Issues in Tourism. 25. 1-19. 10.1080/13683500.2021.1957788.
[18] Dinç, A., Bahar, M. & Topsakal, Y. (2023). Ecotourism research: a bibliometric review. Tourism & Management Studies. 19. 29-40. 10.18089/tms.2023.190103.
[19] Durán-Sánchez, A. &, DelRio, R. & Álvarez García, J. (2017). Bibliometric analysis of publications on wine tourism in the databases Scopus and WoS. European Research on Management and Business Economics. 23. 8-15. 10.1016/j.iedeen.2016.02.001.
[20] Ercan, F. (2023). Smart tourism destination: A bibliometric review. 34. 10.54055/ejtr.v34i.2788.
[21] Fauzi, M. (2023). Dark tourism: a bibliometric review of the past, present and future trends. Tourism and hospitality management. 29. 397-408. 10.20867/thm.29.3.8.
[22] Figueroa, C., Pritchard, A.,Pérez, M, Morgan, N. & Villace-Molinero, T. (2015). Tourism gender research: A critical accounting. Annals of Tourism Research. 52. 10.1016/j.annals.2015.02.001.
[23] Gangadharbatla, H., Bradley, S., & Wise, W. (2013). Event-related skin conductance responses to musical emotions in humans. Journal of Advertising, 42(2-3), 251–263.
[24] Geršak, G. (2020). Electrodermal activity - a beginner's guide. Elektrotehniski Vestnik/Electrotechnical Review. 87. 175-182.
[25] Grabe, M. E., Zhou, S., Lang, A., & Bolls, P. D. (2000). Packaging television news: The effects of tabloid on information processing and evaluative responses. Journal of Broadcasting & Electronic Media, 44(4), 581–598.
[26] Guanghui, Q., Liu, D., Zhang, L. & Huili, Y. (2021). Accessible tourism: a bibliometric review (2008-2020). Tourism Review. ahead-of-print. 10.1108/TR-12-2020-0619.
[27] Gulyas, G. & Molnar, E. (2023). Wellness Tourism Management Research A bibliometric analysis. Management & Marketing. 18. 172-191. 10.2478/mmcks-2023-0010.
[28] Güzel, Ö., Sahin, I., & Ryan, C. (2020). Push-motivation-based emotional arousal: A research study in a coastal destination. Journal of Destination Marketing & Management, 16, Article 100428.
[29] Güzeller, C. & Çeliker, N. (2018). Bibliometric Analysis of Tourism Research for the Period 2007-2016. Advances in Hospitality and Tourism Research (AHTR). 6. 1-22. 10.30519/ahtr.446248.
[30] Hadinejad, A., Moyle, B. D., Kralj, A., & Scott, N. (2019). Physiological and self-report methods to the measurement of emotion in tourism. Tourism Recreation Research, 44(4), 466–478.
[31] Hall, C. (2011). Publish and perish? Bibliometric analysis, journal ranking and the assessment of research quality in tourism. Tourism Management. 32. 16-27. 10.1016/j.tourman.2010.07.001.

[32] Hocevar, M. & Bartol, T. (2021). Mapping urban tourism issues: analysis of research perspectives through the lens of network visualization. International Journal of Tourism Cities. ahead-of-print. 10.1108/IJTC-05-2020-0110.
[33] Johnson, A.G. & Samakovlis, I. (2019). A bibliometric analysis of knowledge development in smart tourism research. Journal of Hospitality and Tourism Technology. 10. 10.1108/JHTT-07-2018-0065.
[34] Kabil, M., Abouelhassan, M., Marzouk, A. & Lóránt Dénes, D. (2022). Gender Perspectives in Tourism Studies: A Comparative Bibliometric Analysis in the MENA Region. Tourism Planning and Development. 10.1080/21568316.2022.2050419.
[35] Kim, J. & Fesenmaier, D. (2013). Measuring Emotions in Real Time: Implications for Tourism Design. 10.1007/978-3-319-03973-2_21.
[36] Kim, S. B., Kim, D. Y. & Bolls, P. (2014). Tourist mental-imagery processing: Attention and arousal. Annals of Tourism Research. 45. 63–76. 10.1016/j.annals.2013.12.005.
[37] Knani, M., Echchakoui, S. & Ladhari, R.. (2022). Artificial intelligence in tourism and hospitality: Bibliometric analysis and research agenda. International Journal of Hospitality Management. 107. 103317. 10.1016/j.ijhm.2022.103317.
[38] Kołodziej, M., Tarnowski, P., Majkowski, A. & Rak, R.. (2019). Electrodermal activity measurements for detection of emotional arousal. Bulletin of the Polish Academy of Sciences, Technical Sciences. 67. 813-826. 10.24425/bpasts.2019.130190.
[39] Li, S. (2019). Emotional appeals in tourism TV commercials: A psycho-physiological study. Journal of Hospitality and Tourism Research, 43(6), 783–806.
[40] Li, S., Scott, N. & Walters, G. (2014). Current and potential methods for measuring emotion in tourism experiences: a review. Current Issues in Tourism. 18. 1-23. 10.1080/13683500.2014.975679.
[41] Li, S., Walters, G., Packer, J. & Scott, N. (2016). Using skin conductance and facial electromyography to measure emotional responses to tourism advertising. Current Issues in Tourism. 1-23. 10.1080/13683500.2016.1223023.
[42] Liu, J., Wei, W., Zhong, M., Cui, Y., Yang, S. & Li, H. (2022). A bibliometric and visual analysis of hospitality and tourism marketing research from 2000–2020. Journal of Hospitality and Tourism Insights. 6. 10.1108/JHTI-10-2021-0277.
[43] Mavric, B , Öğretmenoğlu, M., & Akova, O. (2021). Bibliometric analysis of slow tourism. Advances in Hospitality and Tourism Research (AHTR), 9(1), 157-178.
[44] Merigó, J. M., Mulet-Forteza, C., Valencia, C., & Lew, A. A. (2019). Twenty years of Tourism Geographies: A bibliometric overview. Tourism Geographies, 21(5), 881-910
[45] Miskiewicz, R. (2020). Internet of things in marketing: bibliometric analysis. Marketing and Management of Innovations, 3, 371-381. https://doi.org/10.21272/mmi.2020.3-27
[46] Mitas, O., Mitasova, H., Millar, G., Boode, W., Neveu, V., Hover, M., & Bastiaansen, M. (2022). More is not better: The emotional dynamics of an excellent experience. Journal of Hospitality and Tourism Research, 46(1), 78–99.
[47] Mulet-Forteza, C., Martorell-Cunill, O., Merigó, J. M., Genovart-Balaguer, J., & Mauleon-Mendez, E. (2018). Twenty five years of the Journal of Travel & Tourism Marketing: a bibliometric ranking. Journal of Travel & Tourism Marketing, 1–21. doi:10.1080/10548408.2018.1487368
[48] Muñoz-Leiva, F. (2017). Past themes and future trends in medical tourism research: A co-word analysis. Tourism Management. 65 (2018). 200-211.
[49] Omerzel, D. (2016). A systematic review of research on innovation in hospitality and tourism. International Journal of Contemporary Hospitality Management. 28. 516-558. 10.1108/IJCHM-10-2014-0510.

[50] Padrón Ávila, H. & Hernández-Martín, R. (2020). How can researchers track tourists? A bibliometric content analysis of tourist tracking techniques. European Journal of Tourism Research. 26. 10.54055/ejtr.v26i.1932.
[51] Palmer, A., Sesé, A. & Montaño, J. (2005). Tourism and Statistics: Bibliometric Study 1998–2002. Annals of Tourism Research. 32. 167-178. 10.1016/j.annals.2004.06.003.
[52] Picard, R. W., Fedor, S., & Ayzenberg, Y. (2016). Multiple arousal theory and daily-life electrodermal activity asymmetry. Emotion Review, 8(1),
[53] Rama, D.R., Maldonado-Erazo, C., Durán-Sánchez, A. & Álvarez G. J., J. (2019). Mountain Tourism Research. A Review. European Journal of Tourism Research. Vol. 22. 130-150. 10.54055/ejtr.v22i.380.
[54] Rathi, R., Ruchi, G., Aakanksha, K., & Chhikara, R. (2022). Evolution of luxury marketing landscape: A bibliometric analysis and future directions. Journal of Brand Management. 10.1057/s41262-022-00273-x.
[55] Rojas-Lamorena, A. J., Del Barrio-García, S. & Alcántara-Pilar, J. (2022). A review of three decades of academic research on brand equity: A bibliometric approach using co-word analysis and bibliographic coupling. Journal of Business Research. 139. 1067-1083. 10.1016/j.jbusres.2021.10.025.
[56] Şahin, İ., & Güzel, F.Ö. (2020). Do experiential destination attributes create emotional arousal and memory?: A comparative research approach. Journal of Hospitality Marketing & Management, 29(8), 956–986.
[57] Shahbaz, M., Bashir, M. F., Bashir, M. A., & Shahzad, L. (2021). A bibliometric analysis and systematic literature review of tourism-environmental degradation nexus. Environmental Science and Pollution Research, 28(41), 58241-58257.
[58] Sharma, R. & Rao, P. (2019). Relevance of Impact Studies on the Environmental Impacts of Tourism and Sustainability: A Review and Analysis. 10.4018/978-1-5225-5843-9.ch001.
[59] Shekhar, A. & Valeri, M. (2022). Evolving Themes in Dark Tourism Research: A Review Study. Tourism. 70. 624-641. 10.37741/t.70.4.6.
[60] Shoval, N., Schvimer, Y. & Tamir, M. (2017). Real-Time Measurement of Tourists' Objective and Subjective Emotions in Time and Space. Journal of Travel Research. 57. 004728751769115. 10.1177/0047287517691155.
[61] Şimşek, E. & Kalıpçı, M. B. (2022). Education Quality and Tourism Faculty: A Bibliometric Approach. Journal of Tourism and Services. 25. 189-212. 10.29036/jots.v13i25.412.
[62] Soliman, M., Oleksii, L., Shvindina, H., Figueiredo, R. & Pimonenko, T. (2021). Scientific Output of the European Journal of Tourism Research: A Bibliometric Overview and Visualization. European Journal of Tourism Research. 28. 2801. 10.54055/ejtr.v28i.2069.
[63] Sousa, N., Alén, E., Losada, N. & Melo, M. (2022). Virtual Reality in Tourism Promotion: A Research Agenda Based on A Bibliometric Approach. 1-30. 10.1080/1528008X.2022.2112807.
[64] Su, L., Cheng, J., & Swanson, S. R. (2020). The impact of tourism activity type on emotion and storytelling: The moderating roles of travel companion presence and relative ability. Tourism Management, 81, 1–12.
[65] Su, X., Li, X. & Kang, Y. (2019). A Bibliometric Analysis of Research on Intangible Cultural Heritage Using CiteSpace. SAGE Open. 9. 215824401984011. 10.1177/2158244019840119.
[66] Tarrant, M., Manfredo, M. & Driver, B. (1994). Recollections of Outdoor Recreation Experiences: A Psychophysiological Perspective. Journal of Leisure Research. 26. 357-371. 10.1080/00222216.1994.11969967.

[67] Toker, A. & Oktay, E. (2023). Safety and security research in tourism: A bibliometric mapping. European Journal of Tourism Research. 34. 1-25. 10.54055/ejtr.v34i.2871.
[68] Tuerlan, T., Li, S., & Scott, N. (2021). Customer emotion research in hospitality and tourism: Conceptualization, measurements, antecedents and consequences. International Journal of Contemporary Hospitality Management, 33(8), 2741–2772.
[69] Ye, Q., Li, T., & Law, R. (2013). A coauthorship network analysis of tourism and hospitality research collaboration. Journal of Hospitality & Tourism Research, 37(1), 51-76.
[70] Yuan, Y., Yuen-Hsien, T. & Ho, C. J. (2018). Tourism information technology research trends: 1990-2016. Tourism Review. 74. 10.1108/TR-08-2017-0128.

Review article / Pregledni rad

PREGLED RAZVOJA TEORIJE USLUŽNOSTI PRIMJENOM METODA BIBLIOMETRIJSKE ANALIZE

NIKOLINA POSARIĆ
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
niposari@foi.unizg.hr

LORENA PIKL
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
lpikl@foi.unizg.hr

SAŽETAK

Teorija uslužnosti je jedna od teorija menadžmenta koja se u literaturi često spominje kao suprotnost agencijskoj teoriji, jednoj od najpoznatijih teorija u području menadžmenta i korporativnog upravljanja. Obje teorije nastoje objasniti odnos između vlasnika i menadžera u velikim poduzećima, iako su temeljne pretpostavke uslužnog ponašanja menadžera u velikoj mjeri zastupljene u malim i obiteljskim poduzećima.

Cilj ovog rada je istražiti razvoj teorije uslužnosti pronalaženjem i analizom radova unutar područja društvenih znanosti pomoću bibliometrijskih metoda analize citata i zajedničkih citata. Iz početnog uzorka od 1354 radova, temelj za daljnju analizu bilo je 637 radova. Rezultati prikazuju najistraženije koncepte, ključne časopise, autore, radove i zemlje u području teorije uslužnosti. Ovaj rad prvi prikazuje sveobuhvatan bibliometrijski pregled literature o teoriji uslužnosti te je to prvi pokušaj mapiranja uređene konceptualne strukture razvoja teorije uslužnosti primjenom bibliometrijskih tehnika vizualizacije.

Glavni doprinos ovog rada su rezultati proučavanja literature na strukturiran, sveobuhvatan i objektivan način. Rezultati rada nude istraživačima i znanstvenicima smjernice za istraživanje daljnjih područja u polju društvenih znanosti te omogućuju izgradnju mreže s autorima diljem svijeta koji su značajno pridonijeli razvoju teorije uslužnosti. Na taj način se mogu promovirati i popularizirati temeljne pretpostavke teorije uslužnosti i poticati menadžere na uslužno ponašanje, kao i stvaranje kulture uslužnosti unutar samih organizacija.

KLJUČNE RIJEČI: teorija uslužnosti, uslužnost, bibliometrijska analiza, analiza citata, analiza zajedničkih citata

A REVIEW OF THE DEVELOPMENT OF STEWARDSHIP THEORY USING THE METHODS OF BIBLIOMETRIC ANALYSIS

ABSTRACT

Stewardship theory is one of the management theories often mentioned in the literature as the opposite of agency theory, one of the most famous theories in management and corporate governance. Both theories seek to explain the relationship between owners and managers in large companies, although the basic assumptions of managerial stewardship behavior are mainly present in small and family businesses.

This paper aims to investigate the development of stewardship theory by finding and analyzing papers within the field of social sciences using bibliometric methods of citation and co-citation analysis. From the initial sample of 1354 papers, the basis for further analysis was 637 papers. The results show the most researched concepts, key journals, authors, papers, and countries in the field of stewardship theory. This paper is the first to present a comprehensive bibliometric review of the literature on stewardship theory, and it is the first attempt to map the ordered conceptual structure of stewardship theory development using bibliometric visualization techniques.

The main contribution of this paper is the results of studying the literature in a structured, comprehensive, and objective way. The results of the paper offer researchers and scientists guidelines for researching further areas in the field of social sciences and allow for building a network with authors worldwide who have significantly contributed to the development of stewardship theory. In this way, the basic assumptions of stewardship theory can be promoted and popularized, and managers can be encouraged to practice stewardship behavior and create a culture of stewardship in organizations.

KEYWORDS: stewardship theory, stewardship, bibliometric analysis, citation analysis, co-citation analysis

1. UVOD

Teorija uslužnosti jedna je od teorija menadžmenta koja uz agencijsku teoriju pokušava u prvom redu objasniti odnos između vlasnika i menadžera i to prvenstveno u velikim poduzećima i dioničkim društvima, gdje često dolazi do razdvajanja funkcije vlasništva od upravljačke funkcije. S obzirom na navedenu činjenicu, ova teorija je ujedno jedna od najvažnijih teorija korporativnog upravljanja, uz svima dobro poznatu agencijsku teoriju. Međutim, kroz razvoj teorije uslužnosti, njezine osnovne pretpostavke mogu se prepoznati i u upravljanju malim i obiteljskim poduzećima. Kako tvrde Davis i sur. (2010), teorija uslužnosti je savršena za objašnjavanje upravljanja u obiteljskim poduzećima zbog osobnog ugleda i zadovoljstva vlasnika obiteljskog poduzeća koji prihvaća ulogu uslužitelja u svojoj organizaciji te koji je motiviran prvenstveno interesima organizacije. Stoga se u ovom radu naglasak stavlja na pregled razvoja teorije uslužnosti u obiteljskim poduzećima, odnosno kako je ova teorija postala dominantna za objašnjavanje upravljanja upravo u obiteljskim poduzećima.

Ovaj rad identificira ključna istraživačka područja, trenutnu dinamiku i buduće smjerove razvoja teorije uslužnosti. Bibliometrijska analiza odgovorit će na sljedeća istraživačka pitanja: (1) *Kako se do sada razvila teorija uslužnosti?,* (2) *Koje su ključne riječi teorije uslužnosti?,* (3) *Koji su časopisi, radovi, autori i zemlje najutjecajniji u teoriji uslužnosti?* te (4) *Kakva je struktura razvoja područja teorije uslužnosti i koje teme su bile značajne*? Kako bi se odgovorilo na spomenuta istraživačka pitanja, u radu se koristi bibliometrijski pristup na temelju kojeg se može dati opsežan pregled postojećih istraživanja koja su usredotočena na teoriju uslužnosti. Cilj rada je pružiti strukturiranu, kvantitativnu i objektivnu analizu postojećih istraživanja iz područja teorije uslužnosti čime se mogu identificirati potencijalna područja i nedostaci u istraživanjima koja će budući istraživači moći razmotriti. Prije prikaza rezultata bibliometrijske analize, objasnit će se temeljne pretpostavke i polazišta teorije uslužnosti.

2. TEMELJNE PRETPOSTAVKE I POLAZIŠTA TEORIJE USLUŽNOSTI

Teorija uslužnosti svoje korijene vuče iz psihologije i sociologije, a prema toj teoriji model čovjeka se temelji na menadžeru uslužitelju kojeg karakterizira proorganizacijsko i kolektivističko ponašanje (Davis i sur., 2007). Tipurić i Podrug (2010) naglašavaju da je teorija uslužnosti nastala kao alternativa agencijskoj teoriji, pa su temeljne postavke teorije uslužnosti definirane kao razlikovne postavkama agencijske teorije. Iako, postoje i autori koji tvrde kako je teorija uslužnosti samo poseban slučaj agencijske teorije jer dovode u pitanje temeljnu pretpostavku agencijske teorije prema kojoj se odnos između agenta (menadžera) i principala (vlasnika) uvijek može okarakterizirati agencijskim sukobom (Caers i sur., 2006). Agencijski sukob proizlazi iz suprotstavljenih interesa između menadžera i vlasnika nastalih uslijed razdvajanja funkcije vlasništva i kontrole, gdje menadžer maksimizira vlastitu korisnost na štetu vrijednosti za vlasnike (Badu i Appiah, 2017).

Prema Caers i sur. (2006) postoje dvije struje u razvoju teorije uslužnosti: jedna prikazuje odnos u kojem su ciljevi agenta u sukobu s ciljevima principala, a druga pretpostavlja da su ciljevi agenta savršeno usklađeni s ciljevima principala. Upravo prva struja je ta prema kojoj se teorija uslužnosti smatra posebnim slučajem agencijske teorije jer za razliku od tradicionalne agencijske teorije pretpostavlja da će agent djelovati u skladu s interesima principala i da neće slijediti vlastite ciljeve i interese (Davis i sur., 2007), bez obzira što postoji sukob različitih ciljeva i interesa. Drugim riječima, agent cijeni učinak svojeg djelovanja na korisnost principala i smatra da postizanje vlastitih ciljeva stvara veće troškove te da može postići višu razinu korisnosti kada surađuje s principalom (Caers i sur., 2006).

Podrug i Burazin (2011) ističu da *„iz perspektive teorije uslužnosti menadžeri nisu sebični i vode računa prvenstveno o interesu organizacije“*, odnosno oni *„nastoje dobro obaviti svoj posao i biti dobri upravljači sredstvima poduzeća.“* U tom smislu je temeljna premisa teorije uslužnosti težnja za postojanjem sklada između ciljeva vlasnika i menadžera te uslužni odnos zapravo postoji toliko dugo dok jedna strana ne iznevjeri drugu stranu, a koji onda postaje klasičan agencijski odnos (Tipurić i Podrug, 2010). Davis i sur., (2007) naglašavaju da čak i kad interesi uslužitelja (menadžera) i principala (vlasnika) nisu usklađeni, uslužitelj stavlja veću vrijednost na suradnju nego na pobjedu, ukoliko bi se koristili termini teorije igara.

Temeljni koncept koji se spominje u okviru teorije uslužnosti je koncept uslužnosti. Podrug i Šutalo (2011) navode da se uslužnost može definirati kao *„predanost menadžera pri osiguranju opće dobrobiti na takav način da su dugoročni interesi organizacije prioritet u njegovu*

djelovanju, a ne njegovi vlastiti ciljevi i interesi, niti interesi i ciljevi drugih pojedinaca ili skupina" te sukladno navedenome teorija uslužnosti odbacuje pretpostavku agencijske teorije da je prirodno ponašanje menadžera okarakterizirano kao oportunističko. Kako tvrde (Davis i sur., 1997), uslužitelj štiti i maksimizira bogatstvo dioničara kroz performansu poduzeća te je na taj način i njegova funkcija korisnosti maksimizirana. Tipurić i Podrug (2010) zaključuju da ulaganjem napora u ostvarivanje ciljeva organizacije menadžer može osigurati zadovoljenje osobnih potreba te da je korisnost koja proizlazi iz proorganizacijkog ponašanja znatno veća od korisnosti individualističkog ponašanja.

Podrug (2011) navodi temeljne pretpostavke teorije uslužnosti koje se mogu opisati kroz menadžera koji ima ulogu uslužitelja, sociološki i psihološki pristup upravljanju, model ljudskog ponašanja kojeg karakterizira kolektivističko, proorganizacijsko i vjerodostojno ponašanje, menadžere koji su motivirani ciljevima principala, ciljeve menadžera i principala koji su konvergirani, strukture koje trebaju olakšati i osnažiti, stav vlasnika kojeg karakterizira sklonost riziku te odnos između principala i menadžera koji je zasnovan na povjerenju. Sve navedeno je prikazano u Tablici 1. koja prikazuje temeljne pretpostavke teorije uslužnosti.

Tablica 1. Temeljne pretpostavke teorije uslužnosti

menadžer kao	uslužitelj
pristup upravljanju	sociološki i psihološki
model ljudskog ponašanja	kolektivistički, proorganizacijski, vjerodostojan
menadžeri motivirani	ciljevima principala
interesi menadžera i principala	konvergirani
strukture koje	olakšavaju i osnažuju
stav vlasnika	sklonost riziku
odnos između principala i menadžera temeljen na	povjerenju

Izvor: prilagođeno prema Podrug (2011)

3. PODACI I PROCEDURA PROVEDBE BIBLIOMETRIJSKE ANALIZE

Kako bi se provele metode bibliometrijske analize radova teorije uslužnosti ponajprije je bilo potrebno pripremiti bazu podataka. Važno je spomenuti kako su Zupic i Čater (2015) objasnili "bibliometriju" kao kvantitativnu mjeru za analizu različitih elemenata radova, kao što su časopisi, autori, ključne riječi, države, citati, koautori i slično. S druge strane, bibliometrijska analiza zahtijeva softver za vizualizaciju i mapiranje kako bi se provela kvantitativna analiza (Cobo i sur., 2011). Zbog spomenutog, nakon pripreme konačne baze, korišten je softverski alat VOS Viewer pomoću kojeg je moguće provesti razne oblike mapiranja područja istraživanja, kao i druge analize. Softverski alat VOS Viewer pruža deskriptivnu statistiku među raznim radovima te pomaže u analizi više složene povezanosti između različitih karakteristika radova (primjerice analiza citata, zajedničkih citata ili bibliografsko spajanje) (Van Eck i Waltman, 2009).

Koliko je autorima rada poznato, ne postoji bibliometrijska analiza teorije uslužnosti unutar baze podataka Web of Science. Iako svaka metoda pregleda literature ima određene prednosti i slabosti, ima smisla koristiti nekoliko različitih metoda pri pregledu literature. S obzirom na to da se metodom bibliometrijske analize dosad nije pregledavala literatura iz ovog područja, svakako ju je važno koristiti radi novih spoznaja i brojnih prednosti (Zupic i Čater, 2015).

Prvi korak u analizi citata i zajedničkih citata je određivanje uzorka, odnosno baze radova. Pretraživanje je provedeno u bazi podataka Web of Science koristeći pojam: "stewardship theory". Važno je naglasiti da ne postoje radovi u bazi podataka Web of Science objavljeni prije 1994. godine, a koji se odnose na teoriju uslužnosti. Upravo zbog navedenog, pretraženi su svi radovi od 1994. do 2023. godine, a pretraga je obavljena 10. srpnja 2023. godine. Najprije se primarna baza radova suzila prema sljedećim Web of science indeksima: Social Sciences Citation Index (SSCI), Emerging Sources Citation Index (ESCI), Science Citation Index Expanded (SCI-EXPANDED), Conference Proceedings Citation Index – Social Science & Humanities (CPCI-SSH), Conference Proceedings Citation Index – Science (CPCI-S) i Book Citation Index – Social Sciences & Humanities (BKCI-SSH), što je rezultiralo bazom od 1354 radova.

Nakon toga, primarna baza radova suzila se prema znanstvenom području i vrsti rada. Odabrana su znanstvena područja menadžmenta, poslovne ekonomije, ekonomike, primijenjene psihologije, multidisciplinarne psihologije i multidisciplinarne znanosti, što je rezultiralo sa 648 radova. Na kraju, kao vrsta dokumenta odabrani su članci, pregledni članci, zbornici radova, poglavlja u knjizi i prikazi knjiga. Ovi kriteriji doveli su do baze od 637 radova. Radovi su poredani prema kriteriju relevantnosti u Web of Science bazi podataka. Takvo rangiranje uzima u obzir u kojoj mjeri se naslov, sažetak i ključne riječi svakog rada poklapaju sa zadanim ključnim riječima u pretraživanju. Na kraju su izvezeni podaci o referencama 637 radova koji su bili temelj za daljnju analizu.

4. REZULTATI BIBLIOMETRIJSKE ANALIZE

Kako bi se odgovorilo na prvo istraživačko pitanje, napravljena je vremenska analiza istraživanja teorije uslužnosti od početka (1994.), pa do danas (2023.). Velte (2010) tvrdi da je teorija uslužnosti nastala na temelju opažanja Donaldsona, Davisa te njihovih suradnika. Njihovi prvi radovi su nastali puno ranije od prvih zabilježenih radova u bazi Web of Science, odnosno kako se naglašava u radu Donaldsona i Davisa (1991), prvi puta se teorija uslužnosti kao alternativni pristup agencijskoj teoriji spominje u radovima Donaldsona iz 1985. i 1990. godine. Prvi značajniji rad o samoj konceptualizaciji teorije uslužnosti bio je rad Davisa i sur. (1997), nakon čega slijedi razdoblje slabijeg objavljivanja radova povezanih s teorijom uslužnosti.

Međutim, 2007. godine su Davis i sur. objavili rad u kojem su prikazali rezultate empirijskog testiranja samih pretpostavki teorije uslužnosti te je od te godine vidljiv značajniji porast broja objavljenih radova koji imaju polazište u ovoj teoriji. Nakon te godine objavili su se i prvi radovi koji su testirali temeljne pretpostavke teorije uslužnosti u obiteljskim poduzećima. Jedan od tih radova je i rad autora Zahre i sur. (2008) koji tvrde da obiteljska poduzeća najčešće karakteriziraju povjerenje, nesebična briga, odanost i kolegijalnost, dok su uvjeti koji su povezani s uslužnošću u obiteljskim poduzećima visoka razina identifikacije obitelji s poduzećem, dijeljenje i usklađivanje vrijednosti između obitelji i poduzeća te orijentacija prema dugoročnom uspjehu poduzeća. Novim radom Davisa i sur. (2010) nastavila su se daljnja istraživanja teorije uslužnosti u obiteljskim poduzećima, a isti autori tvrde da je teorija uslužnosti zapravo savršena za objašnjavanje upravljanja u obiteljskim poduzećima. Kao što se može vidjeti iz Prikaza 1., nakon te godine raste broj objavljenih radova koji se vežu uz teoriju uslužnosti, a kao što će se vidjeti u daljnjoj analizi, najveći broj radova se temeljio na istraživanjima provedenima u obiteljskim i malim poduzećima, iako ima i radova koji su se bavili teorijom uslužnosti i u ostalim poduzećima, kao što su javna poduzeća (Simpkins i

Lemyre, 2018), poduzeća iz uslužnog sektora djelatnosti (Kuppelwieser, 2011), ali društvena poduzeća (Bacq i Eddleston, 2018). Ono što se također može vidjeti je i značajan broj objavljenih radova i u prvoj polovici 2023. godine, pa se može zaključiti kako će taj brojka na kraju 2023. godine također biti velika.

Prikaz 1. Vremenska crta radova

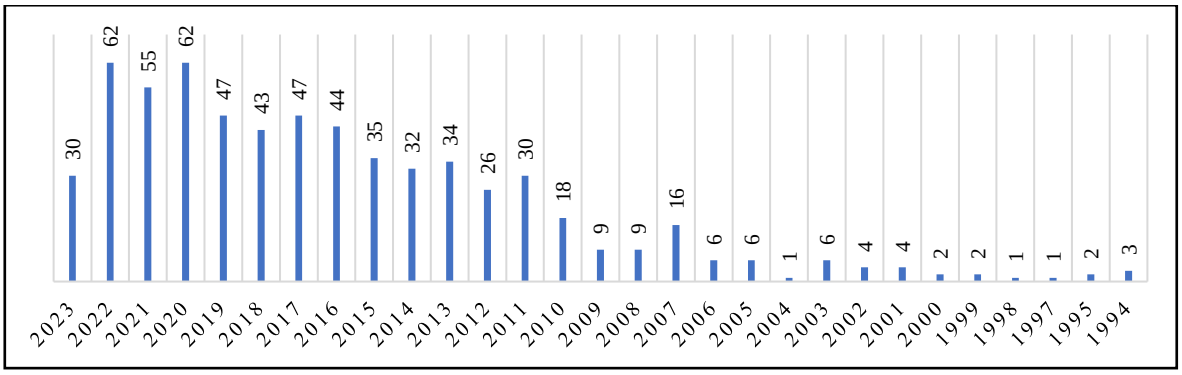

Kako bi se odgovorilo na drugo istraživačko pitanje, napravljena je analiza ključnih riječi. Prikaz 2. prikazuje vizualizaciju ključnih riječi. Analizirano je ukupno 1737 ključnih riječi, od kojih je identificirano10 ključnih riječi koje se navode u nastavku i koje su zadovoljile kriterije od minimalnog broja pojavljivanja, a to je 18. Rezultati pokazuju da ključna riječ teorija uslužnost (*engl. stewardship theory*) ima 133 pojavljivanja i 149 međusobnih veza nakon čega slijedi ključna riječ agencijska teorija (*engl. agency theory*) s vrijednošću pojavljivanja od 102 i 139 međusobnih veza. Ostale ključne riječi povezane s teorijom uslužnosti bile su: korporativno upravljanje (*engl. corporate governance*) (79 pojavljivanja, 85 međusobnih veza), obiteljska poduzeća (*engl. family firms*) (63 pojavljivanja, 41 međusobnih veza), obiteljski posao (*engl. family business*) (47 pojavljivanja, 35 međusobnih veza), uslužnost (*engl. stewardship*) (57 pojava, 29 međusobnih veza), odbor direktora (*engl. board of directors*) (20 pojava, 25 međusobnih veza), uspješnost poduzeća (*engl. firm performance*) (23 pojave, 25 međusobnih veza), uspješnost (*engl. performance*) (18 pojava, 22 međusobnih veza), održivost (*engl. sustainability*) (18 pojava, 10 međusobnih veza). Ovakvi rezultati samo potvrđuju dosadašnje nalaze ove analize prema kojoj se u prvom redu u prvim istraživanjima teorija uslužnosti najviše uspoređivala s agencijskom teorijom i korporativnim upravljanjem, dok su se kasnija istraživanja bavila upravljanjem u obiteljskim poduzećima.

Prikaz 2. Vizualizacija ključnih riječi

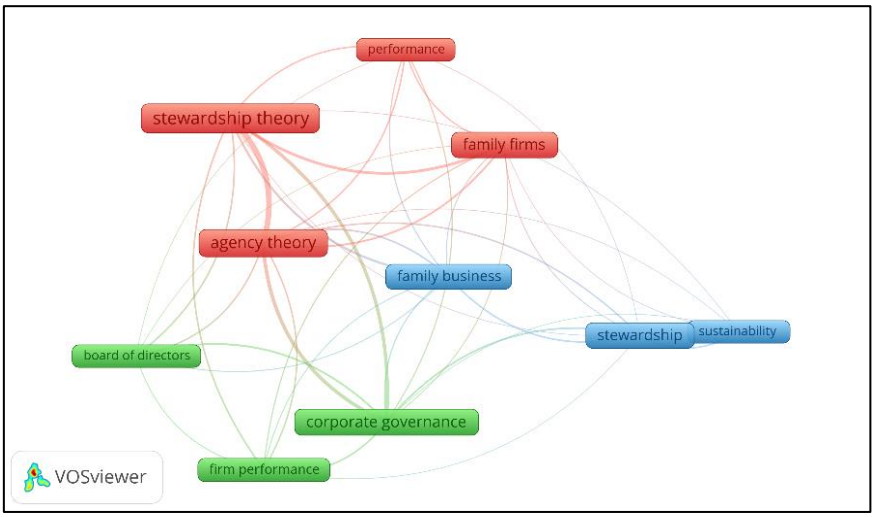

Nadalje, kako bi se odgovorilo na treće istraživačko pitanje, provedena je osnovna analiza citata na konačnoj bazi radova, s ciljem prikaza osnovnih karakteristika područja teorije uslužnosti. Pomoću VOS Viewera izdvojeni su ključni časopisi, ključni autori, ključni radovi i ključne zemlje za spomenuto područje. Kao primarni kriterij značajnosti za sve kategorije (radovi, autori, časopisi i zemlje) korišten je broj citata unutar područja. Analiza ključnih časopisa provedena je kako bi se pronašao najutjecajniji časopis u području. Zadana minimalna vrijednost praga postavljena je na 10 radova po časopisu. Od ukupno 262 radova, devet radova je zadovoljilo zadane uvijete. Iz Tablice 2. se može vidjeti kako časopis *Family Business Review* ima najveći broj radova (29), 2283 citata i 17335 međusobnih veza. Ovo je također u skladu s dosadašnjim nalazima do kojih se došlo provedbom ove analize, a to je da se teorija uslužnosti zapravo najviše povezuje s upravljanjem u obiteljskim poduzećima te se stoga objavljuju takvi radovi u časopisu s tematikom vezanom uz obiteljska poduzeća. Nadalje, *Entrepreneurship Theory and Practice*, ima 16 radova, 1465 citata i 9043 međusobnih veza, dok ga slijedi *Corporate Governance-An International Review*, s 27 radova, 1212 citata i 8843 međusobnih veza.

Tablica 2. Pregled časopisa u kojima su objavljeni značajni radovi

Časopis	Broj objavljenih radova	Broj citata	Broj međusobnih veza
Family Business Review	29	2283	17335
Entrepreneurship Theory and Practice	16	1465	9043
Corporate Governance-An International Review	27	1212	8843
Journal of Small Business Management	13	1064	9475
Journal of Business Ethics	32	1050	7988
Journal of Business Research	28	918	13931
Journal of Family Business Strategy	21	612	15386
Corporate Governance-The International Journal of Business In Society	14	277	4062
Journal of Family Business Management	14	67	6837

Analiza ključnih autora provedena je kako bi se pronašli najutjecajniji autori u području. Zadana minimalna vrijednost praga postavljena je na 5 radova po časopisu. Od ukupno 1496 autora, osam autora je zadovoljilo zadane uvjete. Iz Tablice 3. se može vidjeti kako je autor s najviše radova Kellermanns, F. W., sa 16 radova, 1635 citata i 7584 međusobnih veza. Ovaj autor najviše se bavio različitim istraživanjima upravo u obiteljskim poduzećima. Slijede ga Chrisman, J. J. sa 6 radova, 1420 citata i 2646 međusobnih veza te Eddleston, K. A. s 10 radova, 1234 citata te 4803 međusobnih veza.

Tablica 3. Pregled autora s najcitiranijim radovima

Autori	Broj objavljenih radova	Broj citata	Broj međusobnih veza
Kellermanns, Franz W.	16	1635	7584
Chrisman, James J.	6	1420	2646
Eddleston, Kimberly A.	10	1234	4803
De Massis, Alfredo	6	776	2930
Miller, Danny	5	629	1504
Madison, Kristen	7	248	3637
Kidwell, Roland E.	6	195	3206
Hiebl, Martin R. W.	6	65	2134

Analiza ključnih radova provedena je kako bi se pronašli najutjecajniji radovi u području. Zadana minimalna vrijednost praga postavljena je na 250 citata po radu. Od ukupno 637 rada, 14 radova je zadovoljilo zadane uvjete. Glavni radovi u području prikazani su u Tablici 4. Ako se uzme u obzir i citiranost pojedinog rada, najviše se ističu tri rada, a to su: *"Toward a stewardship theory of management"*, *"Variations in R&D investments of family and nonfamily firms: Behavioral agency and myopic loss aversion perspectives"* te *"Family Governance and Firm Performance: Agency, Stewardship, and Capabilities Family"*. Upravo je rad s najviše citata rad od Davisa, Schroomana i Donaldsona iz 1997. godine.

Tablica 4. Pregled najcitiranijih radova u području

Naslov rada	Godina objave	Broj citata	Broj međusobnih veza
Toward a stewardship theory of management	1997	1995	48
Variations in R&D investments of family and nonfamily firms: Behavioral agency and myopic loss aversion perspectives	2012	783	41
Family Governance and Firm Performance: Agency, Stewardship, and Capabilities Family	2006	632	55
Control and collaboration: Paradoxes of governance	2003	580	55
CEO duality and firm performance: A contingency model	1995	546	31
Destructive and productive family relationships: A steward theory perspective	2007	498	28
Integrating sustainable development in the supply chain: The case of life cycle assessment in oil and gas and agricultural biotechnology	2007	370	2
Beyond agency conceptions of the work of the non-executive director: Creating accountability in the boardroom	2005	365	45
Ownership structures and R&D investments of US and Japanese firms: Agency and stewardship perspectives	2003	315	52
Servant leadership: A review and synthesis	2011	314	4
Implications for GAAP from an analysis of positive research in accounting	2010	283	16
Agency vs. stewardship in public family firms: A social embeddedness reconciliation	2009	266	61
Toward an Understanding of the Psychology of Stewardship	2012	257	46
Are family managers agents or stewards? An exploratory study in privately held family firms	2007	253	34

Analiza ključnih zemlja provedena je kako bi se pronašle najutjecajnije zemlje u području. Zadana minimalna vrijednost praga postavljena je na 25 radova po zemlji. Od ukupno 76 zemlja, devet zemlja je zadovoljilo zadane uvjete. Iz Tablice 5. se može vidjeti kako SAD ima najjače vrijednosti s 220 objavljenih radova, 12897 citata i 143816 međusobnih veza dok ga slijede Kanada, Engleska i Australija. S obzirom na činjenicu da su najcitiraniji autori oni koji dolaze iz SAD-a, ne iznenađuju rezultati koji ukazuju kako u SAD-u ima najveći broj objavljenih radova, citata i međusobnih veza.

Tablica 5. Pregled zemlja s najcitiranijim radovima u području

Zemlja	Broj objavljenih radova	Broj citata	Broj međusobnih veza
SAD	220	12897	143816
Kanada	51	4342	56477
Engleska	75	3319	67178
Australija	32	2823	21452
Italija	42	2016	62507
Njemačka	50	1820	78127

Španjolska	43	1393	55426
Francuska	27	749	26402
Kina	38	737	28781

Kako bi se odgovorilo na četvrto istraživačko pitanje, primijenjena je analiza zajedničkih citata. Provedbom analize zajedničkih citata identificirana su dva zasebna klastera, kao što se može vidjeti na Prikazu 3.. Klastere čine skupovi povezanih radova na temelju analize zajedničkih citata. Mjerenje sličnosti, odnosno povezanosti radova temelji se na pretpostavci da su radovi koji se često zajedno citiraju povezani u većoj mjeri (Zupic i Čater, 2015), što je slučaj i kod dvaju klastera koji su identificirani ovom analizom. Može se primijetiti kako jedan klaster čine Davis i sur. (1997), koji su u svojim radovima često radili usporedbe između agencijske teorije, čiji su idejni začetnici Jensen i Meckling (1976) i teorije uslužnosti. Drugi klaster čine autori koji su se dominantno bavili istraživanjima teorije uslužnosti u obiteljskim poduzećima. Iz ove vizualizacije klastera se najbolje vidi kako je tekao razvoj i primjena teorije uslužnosti od teorijskog okvira, preko mogućih način korporativnog upravljanja u velikim poduzećima, do dominantne primjene u obiteljskim poduzećima.

Prikaz 3. Vizualizacija klastera

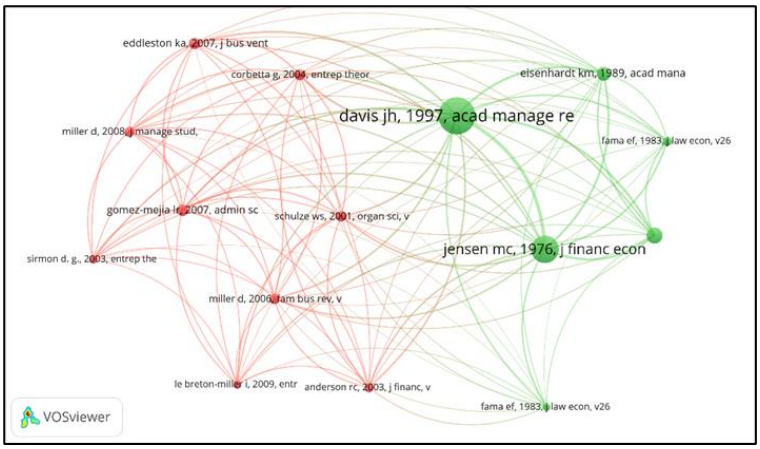

5. RASPRAVA I ZAKLJUČCI

Prije rasprave o rezultatima provedene bibliometrijske analize te iznošenju zaključaka, treba navesti nekoliko ograničenja ovog istraživanja. U prvom redu, provedene su samo dvije bibliometrijske metode i to analiza citata i analiza zajedničkih citata. Osim spomenutih metoda, kao što navode Zupic i Čater (2015), mogu se provesti još bibliografsko spajanje, analiza koautora ili analiza zajedničkih riječi, čime bi se dodatno upotpunili dosadašnji nalazi dobiveni ovom analizom. Također, moglo se vidjeti kako u analizu nisu uključeni stariji radovi jer nisu indeksirani u bazi Web of Science te da su prvi uključeni radovi od 1994. godine nadalje, iako je bilo prikazano da je početak razvoja ove teorije krenuo s prvim radovima Donaldsona iz 1985. i 1990. godine. Također, analiza se fokusirala na pretraživanje baze radova samo korištenjem pojma „teorija uslužnosti“, a dodatno bi se razvoj ove teorije mogao istražiti ako bi se analiza proširila pretraživanjem s pojmom „uslužnost“.

U ovom radu su provedene analize citata i zajedničkih citata kako bi se mogao vidjeti razvoj teorije uslužnosti. Provedenom analizom je utvrđeno da je ova teorija nastala na temelju zapažanja Donaldsona, Davisa i njihovih suradnika koji su u različitim vremenskim

razdobljima osnovne pretpostavke ove teorije provjeravali u različitim vrstama poduzeća. Najprije se teorija uslužnosti promatrala kao alternativa agencijskoj teoriji te su prva istraživanja bila vezana uz usporedbe ovih dviju teorija. Naime, za razliku od agencijske teorije koja pretpostavlja da menadžera (agenta) karakterizira isključivo oportunističko ponašanje i da će on uvijek djelovati u svojem vlastitom interesu, teorija uslužnosti naglašava kako se ponašanje menadžera (uslužitelja) može okarakterizirati kao kolektivističko i proorganizacijsko te da je menadžer kao uslužitelj motiviran dugoročnim ciljevima poduzeća.

Kasnija istraživanja su se najvećim dijelom bavila uslužnošću menadžera u obiteljskim poduzećima jer se pokazalo da je teorija uslužnosti savršena za objašnjavanje upravljanja u obiteljskim poduzećima, sukladno zapažanjima Davis i sur. (2010). Iz vizualizacije klastera koje čine skupovi povezanih radova identificirano je kako je tekao razvoj i primjena teorije uslužnosti od teorijskog okvira, preko mogućih način korporativnog upravljanja u velikim poduzećima, do dominantne primjene upravo u obiteljskim poduzećima.

Daljnji razvoj teorije uslužnosti ide u smjeru da se sve više govori o kulturi uslužnosti u suvremenim obiteljskim poduzećima (Bacq i Eddleston, 2018; Bormann i sur., 2021; Dibrell i Moeller, 2011; Eddleston i sur., 2012; Zahra i sur., 2008), kao i o klimi uslužnosti kao jednoj od vrsti organizacijske klime (Neubaum i sur., 2017). Daljnja istraživanja će najvjerojatnije ići u smjeru razvoja i promoviranja koncepata kulture i klime uslužnosti u svim poduzećima, a ne samo u obiteljskim poduzećima te povezivanja tih koncepta s organizacijskom uspješnošću, održivosti i stavovima zaposlenika prema poslu i prema organizaciji. Suvremeni menadžeri bi svakako trebali voditi računa o implementiranju ovih koncepata u svojim organizacijama, jer kako je utvrđeno i u ovoj analizi, uslužnost se u velikoj mjeri povezuje s organizacijskom uspješnošću te održivim poslovanjem.

REFERENCE

[1] Bacq, S.; Eddleston, K. A. (2018). A Resource-Based View of Social Entrepreneurship: How Stewardship Culture Benefits Scale of Social Impact. *Journal of Business Ethics*, 152(3), str. 589–611.

[2] Badu, E. A.; Appiah, K. O. (2017). The effects of board experience and independence on mitigating agency conflict. *Journal of Accounting in Emerging Economies*, 7(4), str. 445-467.

[3] Bormann, K. C.; Backs, S.; Hoon, C. (2021). What Makes Nonfamily Employees Act as Good Stewards? Emotions and the Moderating Roles of Stewardship Culture and Gender Roles in Family Firms. *Family Business Review*, 34(3), str. 251–269.

[4] Caers, R.; Du Bois, C.; Jegers, M.; De Gieter, S.; Schepers, C.; Pepermans, R. (2006). Principal-agent relationships on the stewardship-agency axis. *Nonprofit Management and Leadership*, 17(1), str. 25–47.

[5] Cobo, M. J.; López-Herrera, A. G.; Herrera-Viedma, E.; Herrera, F. (2011). Science mapping software tools: Review, analysis, and cooperative study among tools. *Journal of the American Society for information Science and Technology*, 62(7), str. 1382-1402.

[6] Davis, J. H.; Allen, M. R.; Hayes, H. D. (2010). Is Blood Thicker Than Water? A Study of Stewardship Perceptions in Family Business. *Entrepreneurship Theory and Practice*, 34(6), str. 1093–1116.

[7] Davis, J. H.; Frankforter, S.; Vollrath, D.; Hill, V. (2007). An Empirical Test of Stewardship Theory. *Journal of Business & Leadership: Research, Practice, and Teaching*, 3(1), str. 40–50.

[8] Davis, J. H.; Schoorman, F. D.; Donaldson, L. (1997). Toward a Stewardship Theory of Management. *Academy of Management Review*, 22(1), str. 20–47.
[9] Dibrell, C.; Moeller, M. (2011). The impact of a service-dominant focus strategy and stewardship culture on organizational innovativeness in family-owned businesses. *Journal of Family Business Strategy*, 2(1), str. 43–51.
[10] Donaldson, L.; Davis, J. H. (1991). Stewardship Theory or Agency Theory: CEO Governance and Shareholder Returns. *Australian Journal of Management*, 16(1), str. 49–64.
[11] Eck, N. J. V.; Waltman, L. (2009). How to normalize cooccurrence data? An analysis of some well-known similarity measures. *Journal of the American society for information science and technology*, 60(8), str. 1635-1651.
[12] Eddleston, K. A.; Kellermanns, F. W.; Zellweger, T. M. (2012). Exploring the Entrepreneurial Behavior of Family Firms: Does the Stewardship Perspective Explain Differences? *Entrepreneurship Theory and Practice*, 36(2), str. 347–367.
[13] Jensen, M. C.; Meckling, W. H. (1976). Theory of the firm: managerial behavior, agency costs and ownership structure. *Journal of Financial Economics*, 3, str. 305–360.
[14] Kuppelwieser, V. G. (2011). Stewardship Behavior and Creativity. *Management Revue*, 22, str. 274–295.
[15] Neubaum, D. O.; Thomas, C. H.; Dibrell, C.; Craig, J. B. (2017). Stewardship Climate Scale: An Assessment of Reliability and Validity. *Family Business Review*, 30(1), str. 37–60.
[16] Podrug, N. (2011). The strategic role of managerial stewardship behaviour for achieving corporate citizenship. *Ekonomski pregled*, 62(7–8), str. 404–420.
[17] Podrug, N.; Burazin, M. (2011). Izazovi teorije uslužnosti u obiteljskim poduzećima. *Ekonomska misao i praksa*, (2), str. 507–526.
[18] Podrug, N.; Šutalo, M. (2011). Institucionalizacija uslužnosti u suvremenim organizacijama. *Ekonomska misao i praksa*, (2), str. 527–542.
[19] Simpkins, L.; Lemyre, L. (2018). Organizational Stewardship: Examining a New Measure in the Stress and Well-Being Framework. *Canadian Journal of Behavioural Science / Revue Canadienne Des Sciences Du Comportement*, 50(3), str. 144–155.
[20] Tipurić, D.; Podrug, N. (2010). Teorijska konceptualizacija i empirijska validacija teorije uslužnosti. *Zbornik Ekonomskog Fakulteta u Zagrebu*, 8(1), str. 66–80.
[21] Velte, P. (2010). Stewardship-theorie. *Zeitschrift Für Planung & Unternehmenssteuerung*, 20, str.285–293.
[22] Zahra, S. A.; Hayton, J. C.; Neubaum, D. O.; Dibrell, C.; Craig, J. (2008). Culture of Family Commitment and Strategic Flexibility: The Moderating Effect of Stewardship. *Entrepreneurship Theory and Practice*, 32(6), str. 1035–1054.
[23] Zupic, I.; Čater, T. (2015). Bibliometric methods in management and organization. *Organizational Research Methods*, 18(3), str. 429-472.

Review article / Pregledni rad

BIHEVIORALNA EKONOMIJA U MARKETINGU I ARHITEKTURA IZBORA*

KARMEN GREGOV
Sveučilište u Zadru
Odjel za ekonomiju
Splitska 1, 23000 Zadar, Hrvatska
karmengregov@gmail.com

ALEKSANDRA KRAJNOVIĆ
Sveučilište u Zadru
Odjel za ekonomiju
Splitska 1, 23000 Zadar, Hrvatska
akrajnov@unizd.hr

JURICA BOSNA
Sveučilište u Zadru
Odjel za ekonomiju
Splitska 1, 23000 Zadar, Hrvatska
jbosna@unizd.hr

SAŽETAK

Bihevioralna ekonomija istražuje ljudsku psihologiju i način na koji ljudi razmišljaju, reagiraju na okolinu i donose odluke u ekonomskom okruženju. Ovaj rad obrađuje područje primjene bihevioralne ekonomije u suvremenom poslovnom okruženju, koje predstavlja 'plodno tlo' par excellence za njeno djelovanje u ispunjenju zacrtanih marketinških ciljeva. U radu se posebice istražuje primjena koncepta poticaja u donošenju odluka u kupovnom procesu, odnosno u dizajniranju tzv. arhitekture izbora, ujedno propitujući ekonomske, društvene i etičke implikacije kada se poticaj koristi kao persuasivni marketinški element. Cilj rada je ispitati koja su to područja marketinga u kojima bihevioralna ekonomija ima najznačajnu primjenu, prikazati nekoliko karakterističnih marketinških modela iz područja bihevioralne ekonomije, te istražiti kakve su implikacije takvog djelovanja, ali i njegove granice. Isto tako, u radu se daje osvrt na neuromarketing kao specifično područje istraživanja. Metodom kritičke analize, autori u radu iznose pregled aktualnog stanja te izazove i predviđenja razvoja teorije i prakse u ovim područjima ispreplitanja marketinga, psihologije, neuroznanosti i socijalne psihologije. Znanstveni doprinos rada očituje se u obogaćivanju konceptualnog okvira primjene bihevioralne ekonomije u marketingu, ali i u propitivanju etičkih, pravnih, praktičnih i drugih granica njene primjene. Riječ je o području koje istražuje faktore donošenja odluka onkraj granica racionalnog razmišljanja i racionalnog donošenja odluka kao postulata klasične ekonomske misli, odnosno o poslovnim modelima koji su utemeljeni na psihološkim mehanizmima kojih često ni sami njihovi protagonisti nisu svjesni, pri čemu je utjecaj i mogućnost korištenja novih tehnologija i digitalnog okruženja praktički nesagledliv. Stoga se radi o osjetljivoj, aktualnoj i intrigantnoj istraživačkoj temi, koja traži daljnja istraživanja i interdisciplinarni pristup.

KLJUČNE RIJEČI: bihevioralna ekonomija, koncept poticaja, arhitektura izbora, etičke granice marketinga, neuromarketing

* Ovaj rad financiran je sredstvima institucionalnog znanstvenog projekta Sveučilišta u Zadru 'MLADCI – Mladi i ekonomija iskustva – nova paradigma i inovativni poslovni modeli“.

BEHAVIORAL ECONOMICS IN MARKETING AND CHOICE ARCHITECTURE

ABSTRACT

Behavioral economics explores human psychology and the way people think, react to their surroundings, and make decisions in an economic environment. This paper works on the field of applied behavioral economics in the modern business environment, which represents the 'fertile soil' par excellence for its action in fulfilling the set marketing goals. The paper particularly investigates the application of the nudge concept in decision-making in the purchasing process, i.e. in the design of the so-called choice architecture, at the same time questioning the economic, social and ethical implications when nudges are used as a persuasive marketing element. The paper objective is to examine in which marketing areas does behavioral economics have the most significant application, to present several characteristic marketing models from the field of behavioral economics, and to investigate the implications of such actions, as well as their limits. Likewise, the paper provides an overview of neuromarketing as a specific area of research. Using the method of critical analysis, the authors present an overview of the current situation and the challenges and predictions of the development of theory and practice in areas where marketing, psychology, neuroscience and social psychology intertwine. The scientific contribution of the paper is manifested in the enrichment of the conceptual framework of the applied behavioral economics in marketing, but also in questioning the ethical, legal, practical and other limits of its application. It is a field that investigates decision-making factors beyond the limits of rational thinking and rational decision-making as a postulate of classical economic thought, i.e. business models that are based on psychological mechanisms that often even their protagonists are not aware of, while the influence and the possibility of using new technology and the digital environment is practically unfathomable. Therefore, it is a sensitive, current and intriguing research topic, which calls for further research and an interdisciplinary approach.

KEYWORDS: behavioral economics, nudge concept, choice architecture, ethical boundaries of marketing, neuromarketing

1. UVOD

Ovaj rad istražuje koncept bihevioralne ekonomije i njenu primjenu u marketingu. U radu se prikazuje istraživački okvir područja bihevioralne ekonomije kroz prizmu preispitivanja klasične ekonomske teorije o racionalnosti pojedinaca u donošenju kupovnih odluka.[1] Cilj istraživanja je otkriti najvažnija područja marketinškog djelovanja u kojima je moguća pojava

[1] Ovaj rad proizlazi iz diplomskog rada K. Gregov ‘Bihevioralna ekonomija u marketingu s osvrtom na globalnu ekonomsku krizu 2020.’ obranjenog na Sveučilištu u Zadru u ožujku 2023. godine.

'anomalija u odlučivanju' od strane kupaca i na koji način ih marketinška teorija i praksa prepoznaju i 'koriste' u donošenju marketinških strategija. U radu se razmatraju i etičke implikacije saznanja o bihevioralnoj ekonomiji, jer se distorzije u donošenju kupovnih odluka često koriste u svrhu povećavanja profita u globalnim kompanijama, mada se isti fenomen može 'upotrijebiti' na koristan i društveno opravdan način, primjerice od strane javnog sektora u smislu poticanja poželjnog ponašanja pojedinaca (primjerice zdrav način života, zdrava prehrana i sl.). Riječ je dakle o svjesnom utjecaju na arhitekturu izbora u kupovnom ponašanju pojedinaca, što je, prema mišljenju autora ovog rada, iznimno važno područje istraživanja u marketinškoj znanosti i praksi. U domaćoj, ali i međunarodnoj literaturi postoji ogroman prostor za daljnja istraživanja o ovom fenomenu, stoga ovaj rad služi i kao poticaj za daljnju znanstvenu raspravu u ovom smjeru.

Ivanković (2015) u svom radu navodi da pojedinci nerijetko donose odluke koje nisu u skladu s njihovim kratkoročnim i dugoročnim ciljevima i navodi: „Nedavna bihevioralna i kognitivna istraživanja pokazuju nam da ova opažanja nisu samo na razini anegdota, već nam upućuju na različite načine na koje svi pojedinci potpadaju pod utjecaj takozvane "arhitekture izbora", koja "gura" trenutne odabire i preferencije u ovom ili onom smjeru." Isti autor smatra da su utjecaji poput okvira u koji se izbor postavlja, fenomena usidrenja, ili averzije prema gubicima samo neki od kognitivnih mehanizama zbog kojih bismo, kako navodi autor, „trebali posumnjati u pretpostavku o *homo economicusu*, biću koje savršeno rezonira o koristi i troškovima, te barata neograničenim kognitivnim kapacitetima, potpunim opsegom relevantnih informacija, velikom dozom vremena i stabilnim preferencijama." (Ivanković, 2015).

Bihevioralna ekonomija pojavila se dakle uslijed manjkavosti u pretpostavci o savršenoj racionalnosti koju su zagovarali klasični ekonomisti i kao takva potaknula je istraživanje anomalija u racionalnom odlučivanju (Camerer, 2005). Znanstvenici su došli do empirijskih saznanja da ograničenja u ljudskom razmišljanju i pažnji, emocije i struktura mentalnog sklopa značajno utječu na donošenje ekonomskih odluka kao i na način na koji ljudi reagiraju na vanjske podražaje (Samson, 2014; Cialdini, 2007). Činjenica da ljudi ne mogu uvijek donositi racionalne odluke te da imaju ograničene kognitivne sposobnosti nije veliko iznenađenje, ali veliki napredak bio je spoznaja da se njihove iracionalne odluke mogu predvidjeti (Plakhin et al., 2018). Bihevioralni ekonomisti primjenjuju ova saznanja na širokom rasponu ekonomskih pitanja u potrošačkoj teoriji, financijama, ekonomiji rada itd. u cilju stvaranja korisnih modela i alata (Camerer, 2005).

Proučavanje zašto se ljudi ponašaju onako kako se ponašaju i kako se na njih može utjecati rezultiralo je konceptom poticaja (eng. *nudging*) kojim se nastoji navoditi ljude da donose bolje odluke za sebe i za društvenu okolinu (Thaler & Sunstein, 2008). Ovakav način intervencije potaknuo je brojna etička pitanja i kritike, ali postoji i mnogo nedostataka u definiranju opsega djelovanja i samoj definiciji poticaja kako bi se taj fenomen mogao pravno regulirati (Lembcke et al., 2019). Isto tako, korištenje bihevioralne ekonomije i njenih saznanja o ljudskim nedostatcima podložno je malverzacijama i manipulacijama i postavlja se pitanje hoće li globalne kompanije stati na stranu zaštite potrošača ili će iskoristiti bihevioralnu ekonomiju kako bi prionuli eksploataciji potrošača u svrhu vlastitih interesa i profita.

„Nudge" teorija je jedno od najvećih postignuća na polju bihevioralne ekonomije u posljednjem desetljeću. Teorija objašnjava kako na pametan način primjeniti „arhitekturu izbora" u poticanju ljudi na donošenje odluka koje će pozitivno utjecati na njihov život.

Teorija ne osporava klasičnu ekonomiju, već joj pomaže u daljnjem razvoju time što pokazuje na koji način ljudi funkcioniraju. Zaključuje da ljudska bića nisu *homo oeconomicus*, te da su često skloni izbjegavanju donošenja malo kompliciranijih odluka ili odluka gdje imaju veliki izbor raznih opcija. Pokazuje kako, uz znanje ljudi razmišljaju. Mali poticaj može dugoročno utjecati razne vidove svakodnevnoga života – financije, ulaganje, štednju, zdravstvenu skrb, promet, zaštitu okoliša, brak, prijateljstvo i sl. (Bulum, 2018).

Marketinški stručnjaci već dugo vremena primjenjuju koncept bihevioralne ekonomije u svojem poslovanju, čak i nesvjesno, ali sustavnijim pristupom prema njegovom korištenju u marketingu mogu se dostići nove razine produktivnosti i uspješnosti (Welch, 2010). Uvidi u način razmišljanja potrošača koje pruža psihologija i njihovo razumijevanje ključni su za razvijanje kvalitetnih i uspješnih marketinških strategija. Korištenje bihevioralne ekonomije i njenih alata kao što je poticaj pokazalo se neizbježnim u marketingu, a osnivanjem bihevioralnih istraživačkih jedinica, mnoge marketinške kompanije pokazale su da se isplati pratiti suvremene trendove. Posljednji podaci pokazuju da danas u svijetu postoji oko 600 bihevioralnih jedinica koje su osnovane pri vladama, u kompanijama i neprofitnim organizacijama. (Soman, Yu & Feng, 2023).

2. BIHEVIORALNA EKONOMIJA

Razvoj ekonomije kroz povijest bio je uvjetovan nadmetanjima brojnih teoretičara koji su htjeli ostaviti svoj trag i razviti nove pravce razmišljanja. Tako je u jednom trenutku prevladalo mišljenje da bi ekonomska teorija, s nastojanjem održavanja stabilnosti u matematičkim modelima i procjenama, trebala počivati na pretpostavci savršenog racionalnog razmišljanja, savršenih informacija te savršene konkurencije i iz svojih modela trebala isključiti emocionalni utjecaj koji je u najmanju ruku kaotičan i nepredvidljiv (Camerer, 2005; Mullainathan & Thaler, 2000). Bilo je samo pitanje vremena kada će znanstvenici shvatiti da su takvi modeli neefikasni i neodrživi, a nakon što su se empirijskim i eksperimentalnim dokazima usprotivili čvrstim predviđanjima neograničene racionalnosti, kao rezultat pojavila se bihevioralna ekonomija (Mullainathan & Thaler, 2000).

3. PRIMJENA BIHEVIORALNE EKONOMIJE U MARKETINGU

Spoznaje bihevioralne ekonomije pronašle su svoju primjenu u marketingu zahvaljujući otkrićima Kahnemana i Tverskog, ali tek kada je započelo značajnije prihvaćanje bihevioralne ekonomije u znanstvenim, javnim i komercijalnim sferama. Neki autori (primjerice Sutherland, 2014, cit. u: The Behavioral Economics Guide 2014) upozoravaju na čestu pojavu moralne averzije prema korištenju psihologije u dizajniranju kupovnog iskustva, zbog čega se često bježi od ove teme, zazireći od toga da se zagazi u područje neetičnoga, ali i iz jednostavnog razloga da se preskoči ambivalentna, kompleksna tema ljudskoga ponašanja i utjecaja na ljudsko ponašanje, posebice u marketingu. No međutim marketinški stručnjaci oduvijek, čak i intuitivno, tragaju za načinima na koji funkcionira psihologija potrošača, ali tek pojavom bihevioralne ekonomije, a samim time i sustavnijim pristupom i dubljim razumijevanjem uzročno-posljedičnih veza u procesu donošenja odluka kod pojedinaca, mogli su dostići veći napredak i bolje marketinške rezultate (Welch, 2010).

Soman, Yu i Feng (2023) slažu se s tezom da su preteče bihevioralne znanosti postojale i ranije, međutim, kako navode, upravo je djelo ‘Nudge’ (‘Poticaj’) Thalera i Sunstaina iz 2008.

godine označilo prekretnicu i dalo legitimitet bihevioralnoj ekonomiji kao znanstvenoj disciplini. Osim toga, značajan doprinos toga djela je i u tome što su Thaler i Sunstain dokazali da ljudsko ponašanje igra fundamentalnu ulogu u ostvarivanju uspjeha organizacije. Isti autori navode: "Promjena situacije u kojoj se donose odluke može dovesti do promjene izbora kojega ljudi donose." (Soman, 2015, cit. u: Soman, Yu & Feng, 2023; 2) Autori nastavljaju s tezom da se prekretnica dogodila kada su Thaler i Sunstain svojim djelom učinili 'obrnuti inženjering' fenomena ljudskog odlučivanja i zapitali se sljedeće: Možemo li kreirati odgovarajuću situaciju koja će navesti ljude na odgovarajući izbor (proces kojega su nazvali 'arhitektura izbora'), bez da signifikantno mijenjamo ekonomske poticaje, pokušaje utjecaja, legislativu ili restrikcije? Navodeći više praktičnih primjera Thaler i Sunstain u tom svom kapitalnom djelu dokazuju da organizacije mogu koristiti arhitekturu izbora "kako bi osnažile znanost i pomogle *stakeholderima* donijeti bolje odluke" (Soman, Yu & Feng, 2023; 2).

3.1. NEUROMARKETING KAO SPECIFIČNO PODRUČJE ISTRAŽIVANJA

Specifično područje istraživanja primjene psihologije u marketingu je neuromarketing. Neuromarketing "koristi najnovije tehnike mjerenja marketinškog stimula...čime se dobiva slika mozga pojedinca, koristeći neinvazivne metode, u svrhu razumijevanja ponašanja potrošača u odnosu na tržište, komercijalne poslove i trgovinu" (Lee, Broderick & Chamberlain, 2007; cit. u: Fortunato, Giraldi & de Oliveira, 2014; 203). Premda je neuromarketing nastao kao srodno područje neuroekonomije (usporedi Braeutigam, 2005, Kenning and Plassmann, 2005, Rustichini, 2005, cit u: Lee, Broderick & Chamberlain, 2007, 199)', koja se, u najširem smislu riječi, bavi istraživanjem funkcioniranja ljudskog mozga u procesu donošenju odluka u ekonomiji, neuromarketing se razvija nešto sporije u odnosu na neuroekonomiju. Lee, Broderick i Chamberlain (2007) u svom radu istražuju kontroverzne aspekte ove istraživačke teme, navodeći pritom kao moguća ograničenja šireg istraživanja u neuromarketingu nedostatak odgovarajuće opreme za neuroistraživanja, nedovoljnu kolaboraciju multidisciplinaranih timova iz neuroznanosti i marketinga, nedovoljnu međuinstitucijsku suradnju, ali prije svega emotivan pristup i etičke prigovore na istraživanja ljudskog mozga u svrhu oblikovanja kupovnih odluka. Tako isti autori citiraju članak iz časopisa Nature Neuroscience iz srpnja 2004. godine (str. 683.) gdje se navodi da postoji opasnost da se ovim istraživanjima "u ljudskom mozgu pronađe 'dugme za kupnju' i tako kreira oglašivačka kampanja kojoj pojedinac neće moći odoljeti". Pritom se, ističu autori, često zaboravlja da je marketinška disciplina znanost, a ne samo praksa. Ističu nadalje da u neuromarketingu nije riječ samo o istraživanju načina funkcioniranja ljudskog mozga u cilju saznanja o načinu i funkcioniranju mehanizama procesa donošenja odluke o kupnji, već je riječ o tome da se u neuromarketingu radi o "razumijevanju, objašnjavanju i predviđanju individualnog, grupnog i organizacijskog ponašanja relevantnog za tržište." (Lee, Broderick & Chamberlain, 2007; 199).

Premda postoji opći konsenzus o neuromarketingu kao kontroverznoj istraživačkoj temi, neki autori ukazuju na to da je područje utjecaja na ljudsku svijest iznimno kompleksno te da postoje brojni alati kojima se može djelovati na potrošača, njegove emocije i odluke o kupnji, kao što su boja, dizajn proizvoda ili promotivne poruke, glazba, miris, okus i mnogi drugi senzorni utjecaji, pored psiholoških utjecaja, koji svjesno ili podsvjesno oblikuju potrošačevu odluku o kupnji. (Krajnović, Sikirić & Jašić, 2012) Stoga je danas gotovo nemoguće razabrati do koje mjere su odluke o kupnji rezultat slobodne volje pojedinca ili su nastale pod nečijim svjesnim (ili nesvjesnim) utjecajem.

3.2. PSIHOLOŠKI PRISTUP MARKETINGU I UTJECAJ

Budućnost razvoja bihevioralne ekonomije nalazi se u većoj inkluziji saznanja iz područja socijalne psihologije (Camerer, 2020). Knjiga Roberta B. Cialdinija (2007) „Utjecaj: znanost i praksa“ ubraja se među deset najutjecajnijih knjiga na području bihevioralne ekonomije (Nobel, 2020; Irrational Labs, 2022). Upravo se u njoj odražava značenje socijalne psihologije unutar bihevioralne ekonomije. Cialdini u navedenoj knjizi opisuje empirijski dokazane ljudske bihevioralne sklonosti koje su utkane u ljudsku povijest, razvoj, opstanak i kulturu te uz pomoć određenih okidača izazivaju spontane predvidive reakcije, koje se često koriste u marketingu. Načela koja su utkana u ljudsku podsvijest i ponašanje, kako navodi Cialdini (2007), su sljedeća: uzajamnost, obveza i dosljednost, socijalna potvrda, naklonost ili sviđanje, autoritet te malobrojnost. Naknadno, u novijim izdanjima Cialdini piše i o jedinstvu koje je bitno za brendiranje (Brikett, 2016). Svi ovi čimbenici ljudskog ponašanja i sklonosti mogu biti podložni „oružju utjecaja“, posebice u marketingu.

3.2.1. Uzajamnost

Načelo uzajamnosti tvrdi da se ljudi osjećaju prisiljeni uzvratiti usluge i vraćati dugove jer im osjećaj da su dužni stvara izrazitu nelagodu (Schenker, 2022). Većina ljudi tako je psihički „programirana“, a izazivanjem okidača kojim osoba osjeća potrebu za recipročnim djelovanjem, na nju se može utjecati da pogoduje određenim ciljevima. Korporacija Amway tako je od obiteljskog biznisa prerasla u tvrtku koja godišnje uprihodi 1,5 milijardi dolara vrijednosti prodaje kućanskih proizvoda „od vrata do vrata“. Njihov model djeluje tako što njihovi prodavači kućanicama ostavljaju tzv. BUG paket s besplatnim uzorcima za razdoblje od 24, 48 ili 72 sati, bez ikakve obveze kupnje (Cialdini, 2007). Klijenti bi u to vrijeme isprobali ponuđene uzorke proizvoda i popustili osjećaju obveze da nešto kupe kad bi se prodavači vratili po uzorke. Nakon toga, prodavač isti BUG paket proslijeđuje sljedećem klijentu (Cialdini, 2007), čime se ciklus nastavlja.

3.2.2. Obveza i dosljednost

Dosljednost je osobina koja se smatra poželjnom, pa je ljudi žele posjedovati kako bi se dokazali sebi i drugima, te kako bi opravdali svoje odluke i stavove. U suštini, svaki put kad se pojedinac obveže, to preuzimanje obveze utječe na čovjekovu sliku o sebi (Leap, 2014). Iako individualno ta obveza možda ima mali utjecaj, rezultati su kumulativni i tijekom vremena mogu drastično promijeniti čovjekovu percepciju (Leap, 2014). Kad je čovjekova slika o sebi promijenjena, ponašanje se također mijenja kako bi se održala dosljednost o slici o sebi (Leap, 2014). Freedman & Fraser (1966) prikazuju istraživanje pri čemu se u jednom stanovnike jednog stambenog naselja upitalo bi li dopustili postavljanje oglasne ploče na kojoj piše VOZI OPREZNO na prilazu ispred njihove kuće. Očekivano, samo 17% je na to pristalo, no iznenađujuće je bilo da je jedna grupa stanovnika tog naselja imala drugačiju reakciju i čak 76% njih je pristalo (Freedman & Fraser, 1966). Toj grupi ljudi prethodno je pristupio drugi volonter i upitao ih da na svoje vozilo stave mali znak VOZI OPREZNO, na što je većina pristala, i samo zbog psihološkog učinka te male geste, dali su pristanak i za postavljanje velike oglasne ploče, kako bi djelovali dosljedno svojim prethodnim stavovima.

Cialdini (2007) navodi još jedan primjer, kupovinu poklona za Božić, kada prodavaonice igračaka često iskorištavaju dosljednost potrošača i nameću im obvezu. U vrijeme oko Božića prihodi prodavaonica igračaka su sigurni, no nakon blagdanskih dana promet drastično pada. U opisanom primjeru, a kako bi osigurali prihode i u mjesecima nakon Božićnih blagdana,

prodavaonice su tijekom Božićnih blagdana agresivno reklamirale skupe igračke čije su količine u trgovinama bile nedostatne za sve kupce koji su ih željeli kupiti. Ogorčeni roditelji tako nisu mogli kupiti igračku koju su obećali svojoj djeci, a jedino što im je preostalo je bilo nabaviti je prvom prilikom kada opet bude dostupna kako bi održali svoje obećanje djeci koje nisu mogli ispuniti za Božić. Tako ne samo što su kupili još zamjenskih igračaka za Božić jer ona koju su obećali nije bila dostupna, nego su ponovno u siječnju kupili skupu igračku kako bi održali obećanje i ostali dosljedni svojoj slici dobrog roditelja. Ova praksa stekla je pozornost i kritiku javnosti i na kraju je i sankcionirana.

3.2.3. Socijalna potvrda

Kada ne znaju na koji način reagirati ili kako se ponašati u određenim situacijama većina ljudi gleda što rade drugi. Kod nesigurnosti u vezi poduzimanja neke radnje, preporuke drugih (ili nedostatak istih) mogu dati podršku za donošenje odluke ili potvrditi izbor da se od nje odustane (Leap, 2014). Socijalna potvrda moćan je alat kojim marketing raspolaže, a koristi se na razne načine, a najčešće iskazivanjem ponašanja drugih kako bi se u potencijalnim kupcima stvorio osjećaj validacije okoline kod donošenja odluke o kupnji. Radi se dakle o tome da su ljudi jednostavno skloni imitiranju drugih. Stručni savjetnik za prodaju i motivaciju Cavett Robert u edukaciji novih prodavača to je zgodno sažeo rekavši: „Budući da su u 95% slučajeva ljudi imitatori, a samo 5% inovatori, ljude više uvjeravaju postupci drugih nego bilo kakav dokaz koji im mi možemo ponuditi.“ (Cialdini, 2007).

Jedan od najmoćnijih načina za korištenje socijalne potvrde je dakle prikazani fenomen „mudrosti gomile“ (Schenker, 2022). Zaključno, veći utjecaj na donošenje odluka kod potrošača imaju drugi potrošači nego sama tvrtka. Da bi to iskoristile, tvrtke koriste zagovaranje svog brenda i svog proizvoda od trećih strana u obliku ocjenjivanja i recenzija proizvoda, oznaka kojima ističu odabire drugih kupaca i najprodavanije proizvode te interakcije i objave sa društvenih mreža (Leap, 2014). Vjerojatno se na tom fenomenu zasniva i rastuća popularnost influencera i njihov utjecaj na donošenje kupovnih odluka.

3.2.4. Naklonost i sviđanje

Ovaj princip je prilično jednostavan, i dobro poznat, a u klasičnom marketingu analizirao se kroz psihološki fenomen selektivne pažnje. Što više se jedna osoba drugoj sviđa, veće su šanse da će ta osoba na drugu utjecati ili je u nešto uvjeriti. Ovo se može očitovati kao ‘sviđanje’ u smislu sličnosti koje dvije osobe dijele, karakterno ili interesno, ali i u površnijem smislu, ‘sviđanju’ na temelju vanjskog izgleda ili ljepote. Tako je korporacija Tuperware iskoristila fenomen sviđanja u svoju korist angažirajući domaćice za predstavljanje njihovih proizvoda, za što su dobivale postotak od prodaje (Cialdini, 2007). Kako Cialdini navodi u spomenutom primjeru Tuperwarea, domaćice bi pozvale svoje prijateljice i obitelj na prezentaciju proizvoda koju bi započele podjelom nagrada za goste (pravilo uzajamnosti), a iako su njihovi gosti bili svjesni da im ti proizvodi zapravo nisu potrebni, iz poštovanja prema prijateljici poslušali bi prezentaciju, a na kraju bi se osjećali primorani da nešto kupe, jer time zaradu ostvaruje i njima bliska osoba. Ovo je korporaciji Tuperware osiguralo izvanredne poslovne rezultate, te su se uspješno iz Amerike proširili u Europu, Latinsku Ameriku i Aziju (Cialdini, 2007).

3.2.5. Autoritet

Snaga percepcije autoriteta povezana je s načelom sviđanja, ali i povjerenja koje nam je utkano u ponašanje od malih nogu kroz sliku roditelja i učitelja, a nastavlja se u odraslom životu kroz stav prema ljudima na vlasti, liječnicima i sl. (Cialdini, 2007). 'Ukrasi' kao što su titule i uniforme daju dojam autoriteta, zbog čega će obična osoba vjerojatnije prihvatiti što ta osoba od autoriteta kaže (Schenker, 2022). Kao dobar primjer kojeg ističe Cialdini (2007) može poslužiti TV reklama u kojoj glumac Robert Young preporučuje gledateljima bezkofeinsku kavu Sank, tvrdeći kako je kofein štetan za zdravlje. Popularnost te reklame omogućila je znatan rast prodaje te se reklama godinama kasnije prikazivala u nekoliko verzija, sve zahvaljujući činjenici da je glumac kojeg su angažirali u reklami glumio doktora u popularnoj TV seriji i – iako logički to nema nikakvog smisla – ljudi su ga doživljavali kao autoritet kada je riječ o zdravlju.

3.2.6. Malobrojnost

„Manje je bolje, izgubljeno je najgore" kaže Cialdini (2007; 204), ističući kako su ljudi vrlo podložni manipulacijama kad im se neki proizvod ili usluga plasiraju kao ograničeni, bilo to vremenski, bilo količinom, te ih kao takve percipiraju kao da više vrijede od drugih. Ljudima je prirodno da reagiraju na način da ne žele propustiti priliku koja će im se ponuditi „samo jednom u životu", pa se lako povedu za marketinškim trikovima uokvirenim (navodonom) oskudnošću. Ovaj princip je jedan od najrasprostranjenijih u marketingu, pa ga se tako može vidjeti na svakom drugom koraku u online kupnji. Stranice za iznajmljivanje smještaja koriste ga porukama o gotovo popunjenim kapacitetima, učestale su poruke trgovaca kako su zalihe nekih proizvoda ograničene, a tu su i popusti kraj kojih stoje satovi odbrojavanja (Schenker, 2022).

3.2.7. Jedinstvo

Princip jedinstva je identitet kojega dijeli osoba koja utječe na nekoga s osobom na koju se utječe, a nadilazi površne sličnosti (Brikett, 2016). Riječ je o kategorijama koje pojedinci koriste da bi definirali sebe i grupe kojima pripadaju kao što su rasa, etnicitet, nacionalnost, obitelj te vjerske i političke sklonosti (Brikett, 2016). U marketingu se ovaj princip koristi stvaranjem grupa s kojima se njihovi članovi identificiraju i osjećaju pripadnost i povezanost s drugim članovima grupe. Korak dalje je poticanje potrošača na ko-kreaciju tako da ih se pita za savjet u vezi proizvoda ili usluge, čime se članovima grupe otvara prostor za iskazivanje svojeg mišljenja što stvara dodatni osjećaj inkluzije (Brikett, 2016). Zato je ovaj princip bitan kod brendiranja gdje se potrošačima plasira ne samo proizvod, već i stil življenja i zajednica kojoj pripadaju. Na tom fenomenu se zasniva i iznimna popularnost društvenih mreža, koje se kao alat također obilato koriste u marketingu, što je već postalo i izdvojeno područje istraživanja.

Sve ove ljudske bihevioralne sklonosti podložne su utjecaju, ali poznavanjem obrazaca ponašanja i razumijevanjem psiholoških procesa, ljude se može potaknuti da djeluju u vlastitom najboljem interesu, najboljem interesu društva ili najboljem interesu tvrtki, ovisno o tome tko je onaj koji 'potiče'.

3.3. POTICAJ U MARKETINGU

Poticaj (engl. *nudging*) se u početku najviše koristio u socijalnom marketingu, ali tvrtkama nije trebalo dugo da shvate njegovu učinkovitost pa je vrlo brzo pronašao svoju primjenu i u komercijalnom marketingu. U kontekstu marketinga poticaj se opisuje kao eksploatacija ljudskog refleksa, duboko ukorijenjenog u funkcioniranje ljudskog mozga, pri čemu taj tzv. *nudge marketing* koristi te reflekse u marketinške svrhe sa ciljem usmjeravanja ponašanja potrošača u smjeru koji pogoduje tvrtki (Schwab, 2022). Ti poticaji mogu biti u korist potrošaču, ali mogu biti i na njegovu štetu. Oni štetni nazivaju su *dark nudges* (mračni ili zlokobni poticaji) i funkcioniraju isto kao i obični poticaji, a najčešće su inkorporirani u *dark patterns* (mračne ili zlokobne uzorke), odnosno iskustva korisnika koja su namjerno loše dizajnirana kako bi se spriječilo korisnike da donesu dobre odluke, naročito ako bi to štetilo tvrtki (Schwab, 2022). Najčešće, kognitivno opterećenje pojedinca je pritom preveliko pa će korisnik popustiti i odabrati onu opciju koju predlaže pružatelj usluge, koja međutim samom korisniku često i nije najisplativija (Schwab, 2022).

Primjer tamnih uzoraka su internet kolačići, za koje neke web stranice imaju jednostavne izbore „Prihvati“ ili „Odbij“. Mnoge se kompanije međutim kroz svoje web stranice i te kako trude svojim korisnicima odbijanje kolačića učiniti što težim, zbog čega ih korisnici najčešće nevoljko prihvaćaju, omogućivši time kompanijama prikupljanje podataka o njima. Korisno poticanje s druge strane korisniku olakšava donošenje odluka, ali upitan je njegov mogući manipulativni učinak. Primjer takvog poticanja je isticanje funkcionalnih pogodnosti proizvoda koje koristi, primjerice, Oysho ili oznake proizvoda sa psihološkim okidačima kao ekskluzivnost ili održivost koje koristi kompanija Zolando (De Weerd, 2019). Pimkie koristi pametne obavijesti koje koriste načelo društvene potvrde kako bi se kupcu pomoglo vidjeti koliko je drugih potrošača gledalo neki proizvod, a Revolve na svojoj web stranici pri izlasku nudi kupon s popustom koji povećava priliku da kupac ostane na stranici i nešto kupi (De Weerd, 2019). Postoje još brojni kreativni načini korištenja poticaja u marketingu, ali se postavlja pitanje: Postoji li ikakva granica u njihovoj primjeni i djelovanju?

Kada se poticanje nađe u rukama vlasti kao alat koji služi za oblikovanje poželjnog ljudskog ponašanja i usvajanja nekih društvenih normi, za pretpostaviti je da će taj alat biti korišten u najboljoj namjeri i bez loših posljedica za pojedince ili društvo u cjelini, što je međutim također diskutabilno. No što se događa kada se taj alat pretoči u digitalne sfere, izmakne nadzoru vlasti i koristi se u ‘sebične’ svrhe kompanija bez ikakve kontrole?

3.3.1. Etičke implikacije poticaja

Poticaji su oduvijek postojali u nekom obliku, premda nikad nisu privlačili toliku pažnju kao danas. Aktualnim definiranjem okvira u kojima poticaji djeluju, porastao je strah od ciljanog iskorištavanja heuristika i pristranosti u ljudskom procesiranju informacija, pa je i broj kritika na poticanje porastao. Lembcke et al. (2019) u svom radu preispituju etičnost digitalnog poticanja te navode kako nisu pronašli nikakva prethodna istraživanja koja se bave tom temom, a takva manjkavost je uistinu zabrinjavajuća. Intervencijski mehanizam, da bi se kvalificirao kao poticaj, mora očuvati slobodu izbora pojedinca, bez prepreka, barijera i ograničenja (Thaler & Sunstein, 2008). U ovim okvirima, poticanje se predstavlja kao etično jer ne narušava slobodu izbora, ali postavlja se pitanje koliko je truda potrebno da pojedinac sa svojim ograničenim kognitivnim sposobnostima svjesno ignorira poticanje i to u okruženju u kojem se kroz digitalne sadržaje ti poticaji javljaju na svakom koraku (Lembcke et al., 2019). Također, poticaji bi, da bili etični, morali biti transparentni, pa se postavlja pitanje

koliko ih je teško otkriti ili koliko se prikrivenosti može tolerirati da bi ih se poticaj smatrao transparentnim? (Lembcke et al., 2019). Alati i tehnike korišteni u digitalnom poticanju utječu na iste psihološke mehanizme - heuristike i pristranosti, kao i u offline kontekstu (Meske & Amojo, 2020). Intervencije poticaja su se pokazale vrijednim alatom u iniciranju bihevioralnih promjena kod pojedinaca. Problem je cijena koja se za to plaća, a to je ometanje autonomnosti, a da bi se to spriječilo digitalno poticanje bi trebalo dizajnirati prema etičkim i tehničkim specifikacijama, ali i tako da su ljudi svjesno dopustili da ih se „potiče“ (Lembcke et al., 2019).

4. ZAKLJUČAK

Richard H. Thaler je godine 2017. dobio Nobelovu nagradu u području ekonomskih znanosti za svoj doprinos bihevioralnoj ekonomiji. Integrirajući ekonomiju i psihologiju, Thaler je inkorpororao psihološki realistične pretpostavke u analize procesa donošenja ekonomskih odluka. Istražujući posljedice ograničene racionalnosti, društvenih preferencija i nedostatka samokontrole kod pojedinaca, dokazao je da ova ljudske karakteristike sustavno utječu na individualne odluke, kao i na tržišne ishode (https://www.nobelprize.org/prizes/economic-sciences/2017/press-release).

Bihevioralna ekonomija integrirana je u društvo i bez njenog razumijevanja teško je holistički sagledati odnose između poduzeća i potrošača čiji je glavni moderator i svojevrsna premosnica upravo marketing. Ova saznanja su još važnija u aktualnoj eri digitalnog marketinga gdje nova tehnologija, veliki podaci, računalstvo u oblaku, AI i drugi suvremeni alati pružaju tvrkama nesagledive mogućnosti.

Razumijevanjem ponašanja potrošača i njegovog procesa donošenja odluka dolazi se do prepoznavanja okidača koji utječu na njegove odluke i načina na koji utječu. Time se stvara poželjna arhitektura izbora, kojom se potrošača navodi i potiče u željenom smjeru. Uzimajući u obzir ljudske nedostatke i kompleksnost psihologije, bihevioralna ekonomija, analizom ljudskog ponašanja i okolnosti koje izazivaju određena ponašanja, pokušava pronaći smisao, konzistentnosti i uzorke te razvijati teorije poduprte empirijskim dokazima. Prakticiranje bihevioralne ekonomije zahtijeva da se ključni metodološki principi moderne ekonomije ne napuštaju, već modificiraju.

Koristi bihevioralne ekonomije u marketingu su brojne, a kontinuiranim razvojem tehnologije i digitalizacijom raste i mogućnost za manipulaciju potrošača u online prostoru, zloupotrebu podataka o potrošačima te kreiranje asimetrične moći u odnosu između poduzeća i potrošača. Vlade i korporacije koje se koriste bihevioralnom ekonomijom u marketingu, moraju obratiti pozornost na etičnost svojih postupaka, kako bi potrošač bio zaštićen od učinaka kojima je često nesvjesno izložen. Korištenje poticaja mora biti jasno i transparentno i potrošač treba biti svjestan poticaja i dati pristanak na njih. No međutim je li to stvarno tako u praksi?

Odgovore na ova važna pitanja treba ponuditi znanost i praksa marketinga, koristećimultidisciplinarni pristup i saznanja socijalne psihologije. Posebno područje istraživanja koje predlažu autori je korištenje saznanja iz bihevioralne ekonomije u ponašanju potrošača u virtualnom prostoru i kroz alate suvremene tehnologije, posebno AI. Čini se da su saznanja iz ovog područja u samom začetku.

REFERENCE

[1] Brikett, A. (2016). CXL, https://cxl.com/blog/cialdini-unity/, preuzeto: [13.09.2022.]

[2] Bulum, B. (2018). Primjena teorije neizravnog poticaja u javnim financijama (Završni rad). Dubrovnik: Sveučilište u Dubrovniku., https://urn.nsk.hr/urn:nbn:hr:155:281036

[3] Camerer, C. F. (2005). CaltechAUTHORS, https://resolver.caltech.edu/CaltechAUTHORS:20110203-151107314, preuzeto [06.12.2021.]

[4] Camerer, C. F. (2020). The Behevioral Economics Guide 2020., http://www.behavioraleconomics.com, preuzeto: [12.05.2021.]

[5] Cialdini, R. B. (2007). Utjecaj: znanost i praksa. Zagreb: MATE d.o.o.

[6] Cialdini, R. B. (2018). The Bihevioral Economics Guide 2018., http://www.behavioraleconomics.com, preuzeto: [08.09.2022.]

[7] De Weerd, J. (2019). CROBOX, https://blog.crobox.com/article/nudge-marketing, preuzeto: [17.09.2022.]

[8] Fortunato, V. C. R., Giraldi, J. D. M. E., & de Oliveira, J. H. C. (2014). A review of studies on neuromarketing: Practical results, techniques, contributions and limitations. Journal of Management Research, 6(2), str. 201, 2014.

[9] Freedman, J. L., & Fraser, S. C. (1966). Compliance without pressure: the foot-in-the-door technique. Journal of personality and social psychology, 4(2), str. 195-202, 1966.

[10] Gregov, K. (2023). Bihevioralna ekonomija u marketingu s osvrtom na globalnu ekonomsku krizu 2020. (Diplomski rad). Zadar: Sveučilište u Zadru.

[11] Irrational Labs (2022). Irrational Labs, https://irrationallabs.com/blog/the-ten-most-influential-behavioral-economics-books/, preuzeto: [05.09.2022.]

[12] Ivanković, V. (2015). Ima li nade za nudge? Libertarijanski, prisilni i anti- paternalizam. Zbornik radova 'Kontrola? Sloboda? Subjekt?' str. 77-95, Zagreb, Hrvatska.

[13] Krajnović, A., Sikirić, D., & Jašić, D. (2012). Neuromarketing and customers' free will. U: Proceedings of the 13th Management International Conference, str. 1143-1163, Budimpšta, Mađarska.

[14] Leap, M. (2014). LinkedIn, https://www.linkedin.com/pulse/20141117160736-168033089-energizing-your-marketing-with-cialdini-s-6-principles-of-influence/, preuzeto: [13.09.2022.]

[15] Lee, N., Broderick, A. J., & Chamberlain, L. (2007). What is 'neuromarketing'? A discussion and agenda for future research. International journal of psychophysiology, 63(2), 199-204, 2007.

[16] Lembcke, T. B., Engelbrecht, N., Brendel, A. B., & Kolbe, L. (2019). To nudge or not to nudge: ethical considerations of digital nudging based on its behavioral economics roots. U: Proceedings of the 27th European Conference on Information Systems (ECIS), str. 1-17, Stockholm i Uppsala, Švedska.

[17] Meske, C., & Amojo, I. J. (2020). Ethical Guidelines for the Construction of Digital Nudges, U: Proceedings of the 53rd Hawaii International Conference on System Sciences 2020, str. 3928-3937, Maui, Hawaii, SAD.

[18] Mullainathan, S., & Thaler, R. H. (2000). National Bureau of economic research, https://www.nber.org/papers/w7948, preuzeto: [31.01.2021.]

[19] Nobel, N. (2020). Impactually, https://impactually.se/your-essential-behavioral-economics-reading-list/, preuzeto: [05.09.2022.]

[20] Nobelprize.org (službena web stranica) https://www.nobelprize.org/prizes/economic-sciences/2017/press-release/, preuzeto: [08.09.2023.]

[21] Plakhin, A., Semenets, I., Ogorodnikova, E., & Khudanina, M. (2018). New directions in the development of neuromarketing and behavioral economics. U: MATEC Web of Conferences 184, članak 04023, str. 1-6, Oradea, Rumunjska.
[22] Samson, A. (2014). The Bihevioral Economics Guide 2014., http://www.behavioraleconomics.com, preuzeto: [03.07.2021.]
[23] Schenker, M. (2022). CXL, https://cxl.com/blog/cialdinis-principles-persuasion/, preuzeto: [13.09.2022.]
[24] Schwab, P. N. (2022). Into The Minds, https://www.intotheminds.com/blog/en/nudge-marketing/, preuzeto: [17.09.2022.]
[25] Soman, D., Yu, J., & Feng, B. (2023). The Behavioral Economics Guide 2023, http://www.behavioraleconomics.com, preuzeto: [12.09.2023.]
[26] Thaler, R. H. i Sunstein, C. R. (2008). Nudge: Improving Decisions about Health, Wealth, and Happiness. New Haven & London: Yale University Press.
[27] Loewenstein, G., Sutherland, R. (2014). The Bihevioral Economics Guide 2014, http://www.behavioraleconomics.com [pristupljeno 03.07.2021.]
[28] Welch, N. (2010). McKinsey Quarterly, https://www.mckinsey.com/business-functions/growth-marketing-and-sales/our-insights/a-marketers-guide-to-behavioral-economics, preuzeto: [06.09.2022.]

Review article / Pregledni rad

ULOGA PROCESA I TEHNOLOGIJA UPRAVLJANJA ZNANJEM U MARKETINGU

SANDRA LOVRENČIĆ
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
sandra.lovrencic@foi.unizg.hr

IVA GREGUREC
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
iva.gregurec@foi.unizg.hr

BRUNO ČOLAN
bruno.colan2@gmail.com

SAŽETAK

Zbog velike količine dostupnih podataka i informacija, posebice u digitalnom okruženju, poduzećima su nužni sustavi upravljanja znanjem u svrhu donošenja optimalnih poslovnih odluka kako na razini cijelog poduzeća, tako i na razini zasebnih funkcija poduzeća, kao što je to marketing. U svrhu uspješnog provođenja procesa upravljanja znanjem, u sam sustav se kontinuirano uključuju različite tehnologije koje omogućuju obradu i analizu velikih količina podataka te prikaz i dijeljenje dobivenih informacija i znanja, pri čemu važnu ulogu igra i umjetna inteligencija. U radu su pojašnjeni procesi upravljanja znanjem i tehnologije koje se koriste za njihovu podršku te je istražena i analizirana uloga koju informacijske tehnologije imaju u marketinškim aktivnostima. Promjene koje kontinuirani napredak tehnologija donosi u svim područjima poslovanja stavljene su u perspektivu upravljanja znanjem s fokusom na njegovu ulogu u marketingu, iz čega je vidljivo da svi procesi upravljanja znanjem kroz podršku korištenih tehnologija mogu omogućiti bolje usmjeravanje marketinških aktivnosti.

KLJUČNE RIJEČI: upravljanje znanjem, marketing, procesi upravljanja znanjem, tehnologije upravljanja znanjem, informacijska tehnologija, umjetna inteligencija

THE ROLE OF KNOWLEDGE MANAGEMENT PROCESSES AND TECHNOLOGIES IN MARKETING

ABSTRACT

Due to the large amount of available data and information, especially in the digital environment, companies need knowledge management systems to make optimal business decisions both at the level of the entire company and at the level of separate company functions, such as marketing. In order to successfully conduct knowledge management processes, in the system are continuously included various technologies, which enable the processing and analysis of large amounts of data, as well as representation and sharing of the obtained information and knowledge, with artificial intelligence also playing an important role. The paper explains the processes of knowledge management and the technologies used to support them, and the role that information technologies play in marketing activities is investigated and analyzed. Changes that the continuous progress of technology brings in all areas of business are put into the perspective of knowledge management with a focus on its role in marketing, from which it is evident that all processes of knowledge management through the support of used technologies can enable better directing of marketing activities.

KEYWORDS: knowledge management, marketing, knowledge management processes, knowledge management technologies, information technology, artificial intelligence

1. UVOD

Poslovanje danas ne može biti uspješno bez informacijskih tehnologija, jer one omogućavaju puno brži pristup velikoj količini podataka te obradu i prikaz tih podataka i informacija, što znatno olakšava pristup potencijalnim kupcima, ali i zadržavanje postojećih. Zbog toga je danas nezamislivo poslovanje bez korištenja informacijskih tehnologija, a isto tako je nezamislivo i provođenje marketinških aktivnosti. Informacijske tehnologije koriste se za razvoj proizvoda i usluga prilagođenih željama i potrebama modernih kupaca s ciljem postizanja veće vrijednosti za kupca, ali s druge strane i profita za poduzeće. Primjena informacijskih tehnologija prepoznaje se i kod odabira cijene i distribucijskih kanala, opet ovisno o ciljanim kupcima. No, najveća promjena događa se u promotivnim aktivnostima, s obzirom da se upravo razvojem tehnologija pojavljuju i novi mediji komunikacije s kupcima koji su sve uključeniji i postaju kreatori vlastite ponude [Chaffey & Ellis-Chadwick, 2022; Kingsnorth, 2022]. Da bi to sve bilo moguće, potrebno je posjedovati bazu podataka o kupcima koja će u konačnici pomoći i u lakšem donošenju poslovnih odluka. Zahvaljujući raznim informacijskim tehnologijama, podatke o kupcima moguće je prikupiti na brojne načine [Chaudhary & Alam, 2022]. Kako bi se velika količina podataka, informacija i znanja uspješno pribavila, obradila i koristila, razvila se disciplina upravljanja znanjem, koja je već i u začetku bila povezana s informacijskim tehnologijama. Stoga se i sve nove tehnologije, uključujući i one vezane uz umjetnu inteligenciju, razmatraju kao mogućnost podrške pojedinoj fazi, odnosno procesu upravljanja znanjem, postajući tako dio sustava upravljanja znanjem u poduzeću, a veliku ulogu igraju i u marketinškim aktivnostima.

Rad je strukturiran na sljedeći način. U drugom poglavlju opisano je upravljanje znanjem te njegovi procesi i tehnologije, a u trećem poglavlju opisane su faze razvoja marketinga uz odgovarajuće informacijske tehnologije. Četvrto poglavlje objašnjava ulogu upravljanja

znanjem u marketingu, dajući primjere tehnologija upravljanja znanjem koje se koriste u marketingu, a zatim povezuje te tehnologije s procesima upravljanja znanjem. U konačnici, u petom poglavlju dani su zaključci rada.

2. UPRAVLJANJE ZNANJEM

Pojam upravljanje znanjem prvi put se spominje krajem 80-ih godina prošlog stoljeća i počeo se razvijati zajedno sa širenjem uporabe informacijskih i komunikacijskih tehnologija te Interneta [Mcinerney & Koenig, 2011]. Iako su neki autori smatrali da će biti u fazi zastarjelosti, odnosno odumiranja do 2025. godine što se tiče razvoja i do 2030. godine što se tiče primjene u organizacijama [De Hoog, 2009], na temelju trenutnog stanja razvoja ne čini se da će se to dogoditi.

Prema McInerney i Koenigu [2011], upravljanje znanjem prošlo je kroz četiri faze razvoja. Prva faza, u prvoj polovici devedesetih godina prošlog stoljeća, bila je vezana uz informacijsku tehnologiju koja se smatra pokretačem upravljanja znanjem, jer može omogućiti brzo i učinkovito dijeljenje znanja. Druga faza, u drugoj polovici devedesetih godina prošlog stoljeća, odnosila se na prepoznavanje važnosti ljudske i kulturalne dimenzije, jer su ljudi ti koji koriste sustave upravljanja znanjem, a također i osiguravaju znanje za njih; stoga se u ovoj fazi smatralo da upravljanje znanjem treba biti dio organizacijske kulture. Naglasak treće faze, u dvije tisućitim godinama, bio je na sadržaju i njegovom dohvaćanju, jer je sve veća količina dostupnih informacija trebala biti strukturirana i opisana kako bi se olakšalo pronalaženje znanja onda kad je to potrebno. U drugom desetljeću dvadeset i prvog stoljeća znanje i informacije izvan poduzeća postaju važniji, a četvrta faza usmjerena je na osiguranje dvosmjernog toka znanja, jer njegova korisnost ovisi o kontekstu i međuodnosu s raznim dionicima, kao što su dobavljači, kupci i konkurencija.

Već krajem devedesetih godina prošlog stoljeća počeo je rasti broj radova koji se bave alatima za upravljanje znanjem i umjetnom inteligencijom, kao i broj radova koji obrađuju ontologije i organizacijske memorije [De Hoog, 2009]. Danas su ta dva pojma međusobno povezana, jer tehnologije umjetne inteligencije imaju veliku ulogu u upravljanju znanjem. Uz tehnologije, vrlo važan element upravljanja znanjem su i procesi koji se odvijaju u poduzeću kako bi znanje nesmetano protjecalo od ulaska u poduzeće do njegove primjene.

2.1. PROCESI UPRAVLJANJA ZNANJEM

Tijekom životnog ciklusa znanje prolazi različite faze i kroz različite procese koji su podržani mehanizmima (organizacijska i strukturalna sredstva, npr. sastanak) i povezanim tehnologijama (npr. video sastanak). Postoji veliki broj podjela procesa, najčešće na četiri do šest [Becerra-Fernandez & Sabherwal, 2014; Dalkir, 2017; Wei & Yeganeh, 2013], no svi oni prate životni ciklus znanja od njegovog ulaska u poduzeće, preko spremanja i obrade pa do primjene i kreiranja novog znanja. Stoga se procese upravljanja znanjem općenito prema protoku kroz poduzeće može podijeliti na [Lovrenčić, 2022]:

- otkrivanje ili pribavljanje znanja – otkrivanje znanja iz dostupnih izvora određenim postupcima ili pribavljanje postojećeg znanja iz poduzeća ili njegove okoline,
- spremanje i čuvanje znanja – daljnja obrada i prikaz znanja te njegovo spremanje i čuvanje za kasniju uporabu,
- dijeljenje znanja – osiguravanje da znanje bude podijeljeno ili dostupno za korištenje u trenutku kad je potrebno određenom djelatniku,

- primjena znanja – korištenje znanja za donošenje odluka i posljedično pokretanje određenih segmenata poslovanja.

S obzirom da procesi slijedno prate ulazak podataka, informacija i znanja u poduzeće, njihovu obradu te dijeljenje i primjenu, važno je da pojedini proces osigura potrebne ulaze za sljedeći proces, odnosno znanje koje organizacija može primijeniti. Kako svaki od ovih procesa utječe na mogućnost poduzeća da donosi optimalne odluke te da uspješno posluje, izrazito je važno osigurati njihovo nesmetano provođenje.

2.2. TEHNOLOGIJE UPRAVLJANJA ZNANJEM

Kao što je već navedeno, razvoj upravljanja znanjem od početka je bio vezan uz brojne informacijske tehnologije. S pojavom Interneta i intraneta dijeljenje znanja unutar organizacije bitno je olakšano [Mcinerney & Koenig, 2011], pri čemu tehnologija ima značajan utjecaj na sve procese i omogućuje njihovo provođenje [Allameh et al., 2011]. Stoga je tehnologija, uz vodstvo, organizaciju i učenje smatrana i smatra se jednim od četiri osnovna stupa upravljanja znanjem, pri čemu su se kao važne tehnologije spominjali e-mail, OLAP, skladišta podataka, pretraživači, podrška odlučivanju, modeliranje procesa i upravljački alati [Stankosky, 2005].

Tijekom godina brojne tehnologije korištene su za upravljanje znanjem, od onih koje se danas smatraju standardnima (na primjer, rudarenje podataka, sustavi za upravljanje sadržajem, sustavi naučenih lekcija, sustavi za lokalizaciju ekspertize, društvene mreže, blogovi, wikiji, e-učenje) do novijih tehnologija povezanih s umjetnom inteligencijom, kao što su analitika velikih podataka (engl. *Big Data Analytics*), strojno učenje (engl. *Machine Learning* – ML), obrada prirodnog jezika (engl. *Natural Language Processing* – NLP), kognitivno računalstvo (engl. *Cognitive Computing*), proširena stvarnost (engl. *Augmented Reality* – AR), Internet stvari (engl. *Internet of Things* – IoT) ili pametni uređaji [Lovrenčić & Sekovanić, 2019]. Istraživanje koje je proveo APQC (2023) sa više od 200 stručnjaka i praktičara iz područja upravljanja znanjem pokazuje da je trenutno pet najvažnijih tehnologija: tehnologije koje omogućuju timski rad, odnosno digitalna radna mjesta, umjetna inteligencija (engl. *Artificial Intelligence* – AI) za preporuku sadržaja ili znanja, grafovi znanja i relacijske baze podataka, inteligentno pretraživanje te automatizacija procesa i radnog toka, a da će za tri godine najvažnija biti umjetna inteligencija za preporuku sadržaja ili znanja, dok će umjesto inteligentnog pretraživanja u prvih pet tehnologija biti umjetna inteligencija za prepoznavanje i izdvajanje ekspertize.

Pojedine tehnologije mogu pridonijeti boljem provođenju jednog ili više procesa upravljanja znanjem. S obzirom da postoji više podjela procesa upravljanja znanjem, razni autori povezivali su s njima i odgovarajuće tehnologije [Becerra-Fernandez & Sabherwal, 2014; Dalkir, 2017; Carvalho & Ferreira, 2001; Fakhar Manesh et al., 2021], ali isto tako su definirali važne tehnologije prema njihovoj ulozi u sustavu upravljanja znanjem [Igbinovia & Ikenwe, 2017; Schmaltz et al., 2004]. Na temelju informacija iz navedene literature vidi se da je vrlo teško izdvojiti tehnologije koje se ne mogu upotrijebiti za poboljšanje procesa upravljanja znanjem. Na primjer, s obzirom na velike količine podataka koje se danas generiraju, nove tehnologije za njihovo prikupljanje, kao što su senzori u sklopu Interneta stvari [Rot & Sobinska, 2018], vrlo su važne u procesu otkrivanja i pribavljanja znanja, dok je rudarenje podataka tehnologija koja se koristi već niz godina [Silwattananusarn & Tuamsuk, 2012]. Analitika velikih podataka [Shabbir & Gardezi, 2020] i strojno učenje [Anshari et al., 2023] važni su za daljnju obradu podataka i dobivanje informacija i znanja. Za spremanje znanja koristi se veliki broj poznatih tehnologija, od klasičnih relacijskih do NoSQL baza podataka, ontologija ili rješenja u oblaku,

pri čemu se znanje sprema u obliku i na način da se olakšava njegovo dijeljenje. Za dijeljenje i primjenu znanja također se koriste razne tehnologije, kao što su grafovi znanja u pozadini razgovornih agenata [Henriquez et al., 2023], koji ujedno znanje i prikupljaju, a primjena znanja omogućena je kroz sustave za podršku odlučivanju ili razne upravljačke sustave [Becerra-Fernandez & Sabherwal, 2014; Dalkir, 2017]. Blockchain tehnologija može podržati cijeli tok znanja kroz poduzeće [Lovrenčić, 2022; Yuman & Goyal, 2022], a veliki jezični modeli također već nalaze svoju primjenu u poboljšanju sustava za upravljanje znanjem [Iqbal, 2023]. Kao primjer su navedene samo neke od raznih tehnologija, stoga su nove tehnologije i umjetna inteligencija neizostavni čimbenik napretka upravljanja znanjem u poduzeću, a time i njegovog cjelokupnog poslovanja.

3. MARKETING I INFORMACIJSKE TEHNOLOGIJE

Razvoj tehnologija posljednjih desetljeća uvelike je utjecao ne samo na promjenu poslovanja poduzeća već i na navike i ponašanje ljudi, pa tako i na marketinške aktivnosti i na način na koji poduzeća gledaju na svoje kupce, zaposlenike, poslovne partnere i ostale dionike na tržištu [Fuciu & Dumitrescu, 2018]. U posljednja tri desetljeća koncept marketinga, a s njim i definicija marketinga, transformira se u upravljački i društveni pristup koji uvažava potrebu stvaranja vrijednosti kako za kupca, tako i za zajednicu i samo poduzeće [Fuciu & Dumitrescu, 2018]. Tijekom desetljeća za potrebe marketinga koristile su se brojne informacijske tehnologije [Graesch et al., 2020], a tijekom vremena se marketing iz marketinga 1.0 transformirao u marketing 5.0.

Marketing 1.0 ili marketing vođen proizvodom [Alanazi, 2022] razvio se tijekom prve industrijske revolucije [Erragcha & Romdhane, 2014] 1950. godine [Sima, 2021] i temeljio se na razvoju proizvoda i proizvodnji tog proizvoda kada su poduzeća imala relativno uzak i plitak asortiman proizvoda, zbog čega kupci nisu imali veliki izbor [Fuciu & Dumitrescu, 2018]. Fokus je bio na kreiranju proizvoda usmjerenog samo na zadovoljenje potreba kupaca sa stajališta proizvođača [Andhyka, 2020], jer su se u ovoj eri poduzeća usredotočila na masovnu proizvodnju i visoku učinkovitost proizvodnje uz niske troškove, a ne na očekivanja potrošača [Alim, 2019]. Može se napraviti povezivanje s Web 1.0 tehnologijama, jer se komunikacija provodila jednosmjerno, a širenje sadržaja uglavnom je bilo vertikalnog tipa, što i danas odgovara slanju e-mail poruka i biltena, primjeni statičnih oglasa te razmjeni poveznica između partnerskih stranica. Marketing 1.0 smatrao se anonimnim, nametljivim i fokusiranim na masovne transakcije [Erragcha & Romdhane, 2014].

Druga evolucija marketinškog koncepta započela je 1970. godine [Sima, 2021] i nazvana je Marketing 2.0 ili marketing usmjeren na kupca [Alanazi, 2022]. Ova era vezana je uz razvoj informacijskih i komunikacijskih tehnologija, a od 1990.-ih godina se koristi Internet, zbog kojeg su se kupci mogli jednostavnije informirati o proizvodima i uslugama te su imali mogućnost uspoređivanja proizvoda i traženja dodatnih informacija. Ovdje se povezivanje može napraviti s Web 2.0 tehnologijama, koje su promijenile komunikaciju iz monologa u dijalog [Alim, 2019; Erragcha & Romdhane, 2014], odnosno omogućile otvaranje interaktivnih komunikacijskih kanala između poduzeća i potrošača [Consoli & Musso, 2010]. Pritom se počela isticati važnost prepoznavanja želja i potreba kupaca te adresiranje i ispunjavanje tih želja [Fuciu & Dumitrescu, 2018]. Za lakšu implementacija Marketinga 2.0 značajno je korištenje Web 2.0 tehnologija ili platformi [Aldhaheri & Bach, 2013]. Tu se najviše ističu društveni mediji, društvene mreže i virtualne zajednice [Baima et al., 2022; Consoli & Musso, 2010; Erragcha & Romdhane, 2014] koje olakšavaju društveno povezaniji web na kojem svatko

može komunicirati, sudjelovati, surađivati te dodavati, uređivati i ažurirati informacijski prostor, odnosno generirati sadržaj (engl. *user generated content*) [Erragcha & Romdhane, 2014] pa se iz tog razloga Web 2.0 tehnologije često svrstavaju u tzv. „društveni web" [Kamel Boulos & Wheeler, 2007; Pachler & Daly, 2009]. Prema literaturi takve tehnologije imaju različite tehničke značajke koje oslobađaju strast za sudjelovanjem u dijeljenju znanja i rješavaju nedostatak tehnologija koje se koriste unutar organizacija [Paroutis & Al Saleh, 2009], te poduzećima olakšavaju prilike za sukreiranje inovacija i to aktivnim uključivanjem kupaca u stvaranje ideje te suradnjom dijeljenjem znanja [Baima et al., 2022].

Marketing 3.0 ili marketing usmjeren na čovjeka [Alanazi, 2022] nastao je 1990. godine [Sima, 2021] kao era vođena vrijednošću i razvojem marketinških aktivnosti usmjerenih korisniku [Alim, 2019]. Ova era evoluirala je od tretiranja pojedinaca kao običnih kupaca, do njihova tretiranja kao ljudskih bića koja imaju um, srce i osjećaje [Kotler et al., 2010]. Stoga je u ovoj eri bilo nužno prilagoditi marketinške aktivnosti kako bi se stvorila i isporučila vrijednost za kupca, s ekonomskog, funkcionalnog, ekološkog, duhovnog i sentimentalnog aspekta [Kotler et al., 2010; Fuciu & Dumitrescu, 2018; Meng & Sidin, 2020]. U ovoj eri kupci su postali osjetljiviji na probleme koji se javljaju u društvu, što mnoga poduzeća čini više usredotočenim na poboljšanje poslovanja i pokušaj postizanja vrijednosti koje zajednica želi [Andhyka, 2020]. To su olakšale Web 3.0 tehnologije koje su kupcima omogućile bolje iskustvo prilikom kupnje angažiranjem njihovih misli, emocija, društvenih interakcija i fizičkih osjetila za stvaranje vrijednosti [Meng & Sidin, 2020]. Također, Web 3.0 tehnologije omogućile su i suradnju kupca i poduzeća u kreiranju vrijednosti (engl. *co-created value*) zbog korištenja inteligentnijeg, intuitivnog weba koji je prilagođen individualnim korisnicima [Erragcha & Romdhane, 2014]. Tijekom razvoja marketinga 3.0 to su najprije bile semantičke tehnologije i inteligentni agenti [Prabhu, 2016], a danas Web 3.0 uključuje i tehnologije kao što su blockchain, pametni ugovori te tehnologije za distribuirano računalstvo i proširenu stvarnost [Waheed et al., 2023].

Marketing 4.0, često nazivan i erom digitalnog marketinga [Alanazi, 2022; Andhyka, 2020] nastao je 2010. godine [Sima, 2021] te podrazumijeva pristup koji i dalje u fokusu ima kupca, ali koji kombinira online i offline interakcije između poduzeća i kupca [Fuciu & Dumitrescu, 2018; Andhyka, 2020] spajajući strojnu i umjetnu inteligenciju s drugim informacijskim i komunikacijskim tehnologijama kako bi se povećala produktivnost i poboljšala interakcija s kupcem u stvarnom vremenu [Fuciu & Dumitrescu, 2018; Alim, 2019]. S obzirom da su kupci ti koji postaju sve zahtjevniji [Vassileva, 2017], od iznimne je važnosti ostvariti i zadržati odnose s njima [Dash et al., 2021]. Glavni cilj Marketinga 4.0 jest predvidjeti buduća kretanja na tržištu i oblikovati marketinške aktivnosti na temelju tog predviđanja upravljanjem podacima i naprednim analitikama za predviđanje budućih trendova [Vassileva, 2017]. Stoga je analitika velikih podataka ključna tehnologija u ovoj eri [Wongmonta, 2021]. Još jedna od tehnologija značajna u ovoj marketinškoj eri jest Internet stvari koji sudjeluje u promjeni marketinških aktivnosti [Dash et al., 2021; Jara et al., 2012].

Marketing 5.0 ili marketing suradnje ljudi i tehnologije [Alanazi, 2022; Wongmonta, 2021] svoje začetke vezuje uz 2020. godinu [Sima, 2021]. Ova evolucija marketinškog koncepta odnosi se na poboljšanje korisničkog iskustva i temelji se na tehnologijama koje oponašaju ljude za stvaranje, komunikaciju, isporuku i povećanje vrijednosti cjelokupnog korisničkog iskustva [Sima, 2021]. Pritom su najčešće spominjane tehnologije Marketinga 5.0 Internet stvari, umjetna inteligencija, virtualna stvarnost (engl. *Virtual Reality* - VR), senzori ili proširena stvarnost [Hermina et al., 2022]. Kao ključni oblik Marketinga 5.0 ovdje se pojavljuje prediktivni marketing koji podrazumijeva očekivanje marketinške potražnje korištenjem proaktivnih radnji [Kotler et al., 2021], a u fokusu ima predviđanje marketinških aktivnosti

korištenjem analitičkih tehnologija [Hermina et al., 2022]. Pritom primjena prediktivnog marketinga rezultira brojnim pozitivnim ishodima, poput povećanja zadovoljstva kupaca, smanjenja troškova marketinga i poboljšanja poslovne uspješnosti [Dung & Lam, 2017].

4. ULOGA UPRAVLJANJA ZNANJEM U MARKETINGU

Marketinške odluke, prema tradicionalnom pristupu, temelje se na odabiru odgovarajućih elemenata marketinškog spleta (proizvoda ili usluge, cijene, promocije i distribucije) za ciljnu skupinu kojoj poduzeće usmjerava sve svoje aktivnosti [Alim, 2019]. No, ovaj pristup usmjeravanja na elemente marketinškog spleta u modernom marketingu, pogotovo onom vezanom uz tehnologije, često se smatra nekonkurentnim i neproduktivnim [Dobrinić & Gregurec, 2016]. U današnje vrijeme nije dovoljno kupce grupirati u velike homogene grupe, već je kupcima potrebno pristupiti individualno, promatrajući njihove jedinstvene potrebe i preferencije [Shaw et al., 2001; Dobrinić, 2011] te u konačnici stvoriti vrijednost za njih [Rowley, 2002; Melović et al., 2021]. U tome će poduzećima pomoći podaci o kupcima, analiza i upravljanje tim podacima, kao i tehnike upravljanja znanjem kao važna imovina modernih poduzeća [Rowley, 2002] koja im omogućava brzo reagiranje ovisno o potrebama kupaca i prilagodbi tržišnim promjenama [Migdadi, 2020], što može biti strateški čimbenik poslovnog uspjeha [Garrido-Moreno et al., 2015], ključan izvor stvaranja i održavanja ekonomskog rasta [Hanvanich et al., 2003], ali i čimbenik postizanja održivosti poslovanja [Zebal et al., 2019] i konkurentske prednosti poduzeća [Paroutis & Al Saleh, 2009].

Upravo se iz tog razloga marketing i upravljanje znanjem često preklapaju, s obzirom da se provođenjem marketinškog istraživanja i praćenjem ponašanja korisnika u digitalnom okruženju prikupljaju ključni podaci i informacije za upravljanje znanjem, podaci poput demografskih, geografskih, psihografskih i ponašajućih karakteristika kupaca koji mogu biti od velikog značaja u transakcijama s kupcima, određivanju odgovarajuće strategije i taktike ostvarivanja i održavanja odnosa s njima. S druge strane, upravljanje znanjem treba biti glavni pružatelj znanja za marketinško komuniciranje, precizno ciljanje kupaca i odabir odgovarajućih komunikacijskih kanala [Bosilj & Jurinjak, 2009], ali i kreiranje novih proizvoda i usluga, određivanje cijena i odabir distribucijskih kanala koji su pravi za kupca.

U literaturi se pojavljuje i pojam marketinškog upravljanja znanjem koje se definira kao „disciplina koja uključuje prepoznavanje i analizu dostupnih i potrebnih marketinških znanja i sposobnosti, te planiranje i kontrolu radnji koje proizlaze iz toga kako bi se razvila marketinška sredstva i sposobnosti u svrhu ispunjavanja organizacijskih ciljeva“ (prema Macintosh's (1998), preuzeto iz [Akroush & Al-Mohammad, 2010]). Pritom se marketinška sredstva i sposobnosti baziraju na: ugrađenim marketinškim sredstvima (poput razvoja marketinške strategije, segmentiranja tržišta, prepoznatljivog ugleda i imidža poduzeća i sl.), uloženim marketinškim sredstvima (poput korisničke usluge, razvoja novih usluga, podizanja kvalitete, razvoja jače marke poduzeća i sl.), mogućnostima internog marketinga (poput razvoja marketinških programa bolje nego što to rade konkurenti po pitanju svih elemenata marketinškog spleta, boljeg upravljanja ljudskim potencijalima i sl.) te mogućnostima vanjskog marketinga (poput razumijevanja želja i potreba kupaca, stvaranja dugoročnih odnosa s kupcima, analize čimbenika makro i mikrookruženja i sl.) [Akroush & Al-Mohammad, 2010]. Stoga marketinško upravljanje znanjem upućuje na specifični opseg znanja koje se odnosi na marketinške procese [Al-Dmour et al., 2020], odnosno na pokrivanje svih faza upravljanja marketingom, dakle faza analize, planiranja, implementacije i kontrole [Dobrinić & Gregurec, 2016].

Razvojem novih tehnologija potiče se razmjena ideja i znanja između kupaca, ali i između kupaca i poduzeća [Baima et al., 2022]. S tehnologijama se razvijaju i informacijski sustavi, a s njima se prilagođava i način upravljanja marketingom, jer tehnologije poduzećima daju ogromnu sposobnost prikupljanja i obrade velikih količina podataka o svojim kupcima i to uvidom ne samo u njihove karakteristike, već i u preferencije i obrasce ponašanja [Shaw et al., 2001]. Prvenstveno se ovo najviše odražava na povećanje učinkovitosti marketinga odnosa (engl. *Relationship Marketing - RM*) [Rowley, 2004], upravljanja odnosima s kupcima (engl. *Customer Relationship Management - CRM*) [García-Murillo & Annabi, 2002; Gebert et al., 2003; Stefanou et al., 2003; Garrido-Moreno et al., 2015] koji svoje korijene vuče upravo iz marketinga odnosa [Rowley, 2002], kao i marketinga baze podataka (engl. *Databased Marketing - DM*) [Shaw et al., 2001; Eren & Erdoğmuş, 2004] koji u fokusu ima kreiranje predikcijskih modela.

Upravljanje znanjem i marketing odnosa dvije su važne paradigme koje se s jedne strane bitno razlikuju, a s druge je u srži obje komunikacija, povjerenje, dijeljenje znanja i lojalnost koji su temeljeni na podacima i informacijama o kupcima koje pomažu u kreiranju odgovarajućih proizvoda i usluga, kao i postizanju sveukupnog uspjeha poduzeća [Rowley, 2004].

No, trendovi uzrokovani globalizacijom i napretkom informacijskih tehnologija potiču poduzeća da razmišljaju više o svojim kupcima i da se čim više usredotoče na njih i ostvarivanje njihova zadovoljstva i lojalnosti u svrhu postizanja konkurentskih prednosti i maksimiziranja profita [Stefanou et al., 2003; Baima et al., 2022]. Stoga je poslovanje usmjereno na korisnike (engl. *customer-centric*) s ciljem uspostavljanja i razvoja dugoročnih odnosa s kupcima, kao jedna od osnovnih okosnica marketinške strategije upravljanja odnosima s kupcima, relacijski orijentirano poslovanje koje nastoji stvoriti uzajamnu korist kako za korisnika tako i za poduzeće [Bose, 2002; Stefanou et al., 2003]. Ono što je za upravljanje odnosima s kupcima važno jest i znanje koje se unutar poduzeća dijeli u svrhu učinkovitijeg poslovanja i često se smatra ključnom imovinom poduzeća [Garrido-Moreno et al., 2015; Al-Dmour et al., 2020; Baima et al., 2022]. To znanje temelji se na znanju ugrađenom u ljude [Migdadi, 2020], a odnosi se na:

- znanje za kupce koje podrazumijeva njihovo znanje o proizvodima, uslugama, cijenama, tržištima i dobavljačima, što pridonosi prilagodbi transakcija prije, tijekom i nakon kupnje te omogućava kupcima da bolje upoznaju samo poduzeće,
- znanje o kupcima koje uključuje osnovne informacije o kupcima poput imena, kontakta, demografskih karakteristika, a akumulira se znanjem o motivaciji kupaca i njihovim kupovnim navikama, preferencijama, očekivanjima, željama i potrebama, na temelju čega dolazi do personalizirane komunikacije između kupca i poduzeća,
- znanje od kupaca koje proizlazi iz interakcije s kupcima i predstavlja ideje, preporuke, trendove, prijedloge i iskustva korištenjem proizvoda ili usluga i koje može pomoći u poboljšanju proizvoda i usluga poduzeća [Rowley, 2002; García-Murillo & Annabi, 2002; Gebert et al., 2003; Muniz et al., 2020], te u zadnje vrijeme često spominjano
- znanje s kupcima koje podrazumijeva znanje koje je sukreirano s kupcima kroz dugoročni odnos s ciljem ostvarivanja vrijednosti za obje strane [Khosravi et al., 2017; Jaziri, 2019].

Ovdje je potrebno istaknuti kako postojanje dovoljnog i kontinuirano ažuriranog znanja iz svih skupina može biti ključno za učinkovitu implementaciju i provođenje strategije upravljanja odnosima s kupcima [Stefanou et al., 2003] i da se upravo upravljanje znanjem često smatra pokretačkom snagom koja stoji iza provedbe strategije upravljanja odnosima s kupcima

[Garrido-Moreno et al., 2015], stoga brojna poduzeća integriraju upravljanje znanjem i upravljanje odnosima s kupcima [Migdadi, 2020].

Marketing baza podataka može se promatrati jednim od alata temeljenom na upravljanju znanjem o kupcima. Poduzeća se često pozivaju na svoju bazu podataka u kojoj imaju sve potrebno za poznavanje svojih kupaca, a time i planiranje svoje marketinške strategije temeljene na znanju o kupcima i odnosima jedan na jedan [Eren & Erdoğmuş, 2004]. Zbog nedostatka odgovarajućih alata i tehnika za analizu velikih količina podataka i obilje informacija o kupcima i njihovim obrascima ponašanja prilikom kupnje često su baze podataka, a time i marketing baza podataka nedovoljno iskorišteni. No, tri glavna područja primjene rudarenja podataka za marketing temeljen na znanju su: profiliranje kupaca, analiza odstupanja i analiza trendova [Shaw et al., 2001]. Kreiranje profila kupaca pomaže poduzećima da donesu prave marketinške odluke te koriste odgovarajuće strategije i taktike za prepoznavanje potreba određenih kupaca. Prepoznavanje odstupanja od normale iznimno je važno za poduzeća jer na taj način, vezano uz profiliranje, prepoznaju anomalije koje se javljaju, a alati za rudarenje podataka pružaju moćna sredstva poput neuronskih mreža za otkrivanje i klasificiranje takvih odstupanja. Analiza trendova podrazumijeva i promatranje obrazaca ponašanja tijekom određenog vremena. U ovom slučaju vizualizacija podataka dobivenih rudarenjem pomaže u otkrivanju trendova, pritom olakšavajući procjenu pojedinih marketinških programa ili predviđanja buduće prodaje kreiranjem predikcijskih modela ponašanja [Shaw et al., 2001].

4.1. TEHNOLOGIJE UPRAVLJANJA ZNANJEM I MARKETING

Iz prethodnog poglavlja vidljivo je da se u marketingu koriste brojne tehnologije za različite marketinške domene [Graesch et al., 2020], koje se u poduzeću mogu promatrati i kao integrirani dijelovi sustava upravljanja znanjem. Kako postoje razne mogućnosti korištenja tehnologija upravljanja znanjem za potrebe marketinga, u nastavku se navodi nekoliko primjera.

Alati za rudarenje podataka mogu pomoći u otkrivanju skrivenih znanja i boljem razumijevanju samih kupaca, dok sustavi upravljanja znanjem mogu kanalizirati znanje u učinkovite marketinške strategije i to pomoću strategije upravljanja odnosima s kupcima [Shaw et al., 2001] koja poduzećima omogućava poznavanje svojih kupaca, bolje razumijevanje njihovih potreba i komunikaciju s njima na personaliziranoj razini, kao i prilagodbu proizvoda i usluga pojedincima na temelju razumijevanja njihovih želja i potreba, što često olakšava održavanje dugoročnih odnosa s njima [Garrido-Moreno et al., 2015]. Stoga i upravljanje odnosima s kupcima kao marketinška strategija i upravljanje znanjem imaju u fokusu preraspodjelu resursa pratećih poslovnih aktivnosti, a njihova sinergija olakšava stvaranje konkurentskih prednosti [Gebert et al., 2003]. Razlog tomu je što se znanje o kupcima, znanje za kupce, znanje od kupaca ili znanje s kupcima, kao i razina korisničke usluge i zadovoljstva kupaca smatraju značajnima u stvaranju i zadržavanju konkurentske prednosti poduzeća [Baima et al., 2022]. Stoga je neupitno da bi poduzeća trebala istražiti i poboljšati metode i tehnologije upravljanja znanjem za potrebe strategije upravljanja odnosima s kupcima kako bi dobila znanja s dodanom vrijednošću za sebe i svoje kupce i razumjela ne samo obrasce ponašanja i trendove, već i stavove i preferencije kupaca [Romano Jr., 2000].

Umjetna inteligencija zadnjih je godina privukla veliki značaj i znanstvenika u području marketinga, s obzirom da znatno olakšava poduzećima prikupljanje podataka, a da to nije tradicionalno istraživanje tržišta. Procesi prikupljanja podataka pomoću umjetne inteligencije smatraju se manje nametljivima, što bitno može smanjiti potencijalnu pristranost ispitivača ili

promatrača. Primarne, nestrukturirane i nenumeričke izvore podataka pomoću teksta, zvuka, slike ili videa moguće je automatski prikupljati i uspoređivati s podacima dobivenima s različitih platformi te je sama analiza prikupljenih podataka pojednostavljena, što olakšava prilagodbu ponude pojedincima [Kopalle et al., 2022]. Razgovorni agenti temeljeni na umjetnoj inteligenciji također su primjer novih tehnologija namijenjenih poboljšanju odnosa s kupcima [Lucy, 2023]. Očekuje se da bi u budućnosti umjetna inteligencija mogla imati puno veći utjecaj na marketinške aktivnosti, marketinške i prodajne procese, korisničku službu i ponašanje kupaca općenito [Davenport et al., 2020] .

Blockchain tehnologija također se u zadnje vrijeme pokazuje kao jedna od ključnih tehnologija koja omogućava interakciju između poduzeća i njihovih kupaca. Najčešća primjena je u e-trgovini, upravljanju opskrbnim lancem, u sprječavanju prijevara u digitalnom marketingu, u digitalnom oglašavanju, na društvenim mrežama općenito, kao i na tržištu podataka na kojem se često temelje i programi lojalnosti u kojima se ova tehnologija koristi [Stallone et al., 2021]. Shrestha et al. [2020] sugeriraju da blockchain tehnologija može (1) poboljšati pozicioniranje robne marke i imidž robne marke usvajanjem digitalnih valuta specifičnih za marku i povećati mogućnosti pripovijedanja (engl. *storytelling*) robne marke te (2) autentificirati komunikaciju robne marke i stoga poboljšati povrat ulaganja oglašavanja smanjivanjem potrebe za posrednicima [Boukis, 2019; Macnamara et al., 2016].

4.2. PROCESI UPRAVLJANJA ZNANJEM I MARKETING

S obzirom da je važan cilj sustava upravljanja znanjem osiguravanje podrške procesima navedenima u poglavlju 2.1., tehnologije upravljanja znanjem mogu se uspješno primijeniti za potrebe marketinga, ako je i u kontekstu marketinških aktivnosti ta podrška osigurana. Stoga će se tehnologije koje se koriste za ostvarivanje marketinških ciljeva staviti u kontekst podrške procesima upravljanja znanjem.

Kao što je ranije navedeno, zbog vrlo velike količine podataka o kupcima, njihovo prikupljanje i analiza važan su prvi korak uspješnog marketinga u poduzeću. Velike mogućnosti za prikupljanje podataka koje daje Internet stvari, ali i virtualna i proširena stvarnost, te razne tehnologije za rudarenje podataka, uključujući i neuralne mreže, daju jaku podršku procesu pribavljanja i otkrivanja znanja, a prikupljeni podaci se, osim u marketingu, mogu koristiti i za ostala područja poslovanja poduzeća u smislu upravljanja znanjem kako bi se donosile optimalne odluke i ostvarili ciljevi poduzeća. Strojno učenje, a naročito analitika velikih podataka imaju vrlo značajnu primjenu u marketingu zbog važnosti dobivanja informacija i znanja (kao što su prediktivni modeli ponašanja kupaca) koje će usmjeriti marketinške aktivnosti ka zadržavanju postojećih i privlačenju novih kupaca, a mogu dati podršku i procesu pribavljanja i otkrivanja znanja, kao i procesu spremanja i čuvanja znanja, kako bi se ono spremilo u obliku prikladnom za daljnje korištenje. Važan dio modernog marketinga, marketing baze podataka, može se ostvariti raznim tehnologijama za spremanje neobrađenih podatka te obrađenih informacija i znanja, od klasičnih relacijskih baza, NoSQL i distribuiranih baza podataka, rješenja u oblaku ili blockchain tehnologije, a koje su također podrška procesu spremanja i čuvanja znanja.

Razne tehnologije koje se koriste za marketinške aktivnosti, naročito za upravljanje odnosima s kupcima, daju podršku procesu dijeljenja znanja. To su razne Web 2.0 i Web 3.0 tehnologije, kao što su društvene mreže, razgovorni agenti ili virtualna i proširena stvarnost. Tehnologije za vizualizaciju podataka i informacija omogućuju njihovo lakše razumijevanje i dijeljenje, a također i tehnologije korištene za spremanje znanja u odgovarajućem obliku. Znanje koje je

dostupno obrađeno i u prikladnom obliku omogućava i optimalnu primjenu za donošenje odluka o marketinškoj strategiji i drugim segmentima poslovanja, čime se daje podrška procesu primjene znanja. Automatska primjena znanja moguća je kroz kombinaciju raznih tehnologija, na primjer u sustavima preporuke kupcima, odnosno sustavima podrške odlučivanju.

Iz navedenog je neosporno vidljivo kako se marketinške aktivnosti i aktivnosti upravljanja znanjem, odnosno procesi, kao i korištene tehnologije isprepliću te se mogu koristiti u sinergiji za dobrobit svih ostalih aktivnosti koje su važne za uspjeh poslovanja poduzeća. Tehnologije koje se koriste za marketinške aktivnosti daju podršku svim procesima upravljanja znanjem, na temelju čega se ti procesi mogu uspješno provoditi i osigurati neometani tok znanja kroz poduzeće te tako povratno dati podršku marketinškim aktivnostima. Na taj se način iskoristivost svih resursa poduzeća može maksimizirati uz smanjivanje troškova.

5. ZAKLJUČAK

S obzirom da se područje upravljanja znanjem i dalje razvija, predstavlja zanimljive izazove kako za istraživače, tako i za praktičare. Pogotovo ako se u obzir uzmu područja marketinga u kojima se upravljanje znanjem primjenjuje, poput marketinga baze podataka i upravljanja odnosima s kupcima, a koja su i sama još u razvoju. No, u trenutnom poslovnom okruženju usmjerenom na korisnika, očita je uloga upravljanja znanjem za marketing i podršku u marketinškom odlučivanju svakog modernog poduzeća pritom pokrivajući jedan od osnovnih ciljeva, postizanje konkurentske prednosti.

Povezanost i mogućnost primjene tehnologija koje se koriste za upravljanje znanjem i marketinške aktivnosti i u drugim područjima poslovanja poduzeća omogućava bolje povezivanje raznih odjela, a time i veću povezanost svih resursa. Takvo povezivanje više aspekata poslovanja s upravljanjem znanjem vodi ka holističkom pristupu koji može donijeti brojne prednosti poduzeću. Ovaj članak prikazuje upravo kako dva područja, upravljanje znanjem i marketing, u sinergiji daju bolje rezultate i kreiraju veću vrijednost, ne samo za poduzeće nego i za same kupce.

REFERENCE

[1] Akroush, M. N., & Al-Mohammad, S. M. (2010). The effect of marketing knowledge management on organizational performance: An empirical investigation of the telecommunications organizations in Jordan. *International Journal of Emerging Markets, 5*(1), 38–77. https://doi.org/10.1108/17468801011018266

[2] Alanazi, T. M. (2022). Marketing 5.0: An Empirical Investigation of Its Perceived Effect on Marketing Performance. *Marketing and Management of Innovations*, *13*(4), 55–64. https://doi.org/10.21272/mmi.2022.4-06

[3] Aldhaheri, A., & Bach, C. (2013). *How to implement Marketing 2.0 Successfully* (arXiv:1308.4894). arXiv. https://doi.org/10.48550/arXiv.1308.4894

[4] Al-Dmour, H., Asfour, F., Al-Dmour, R., & Al-Dmour, A. (2020). Validation of the impact of marketing knowledge management on business performance via digital financial innovation as a mediating factor. *VINE Journal of Information and Knowledge Management Systems, 52*(1), 33–56. https://doi.org/10.1108/VJIKMS-05-2020-0085

[5] Alim, L. (2019). The Impact of Industrial Revolution to Marketing. If you are inserting The Impact of Industrial Revolution to Marketing now its here. *Electronic Research Journal of Social Sciences and Humanities*, *1*(4), 114–122.
[6] Allameh, S. M., Zare, S. M., & davoodi, S. mohammad reza. (2011). Examining the impact of KM enablers on knowledge management processes. *Procedia Computer Science*, *3*, 1211–1223. https://doi.org/10.1016/j.procs.2010.12.196
[7] Andhyka, B. (2020). Marketing 4.0 a Literature Review. *IOSR Journal of Business and Management*, *22*(4), 49–52.
[8] Anshari, M., Syafrudin, M., Tan, A., Fitriyani, N. L., & Alas, Y. (2023). Optimisation of Knowledge Management (KM) with Machine Learning (ML) Enabled. *Information*, *14*(1), Article 1. https://doi.org/10.3390/info14010035
[9] Baima, G., Santoro, G., Pellicelli, A. C., & Mitręga, M. (2022). Testing the antecedents of customer knowledge sharing on social media: A quantitative analysis on Italian consumers. *International Marketing Review*, *39*(3), 682–705. https://doi.org/10.1108/IMR-03-2021-0122
[10] Becerra-Fernandez, I., & Sabherwal, R. (2014). *Knowledge Management: Systems and Processes*. Routledge.
[11] Bose, R. (2002). Customer relationship management: Key components for IT success. *Industrial Management & Data Systems*, *102*(2), 89–97. https://doi.org/10.1108/02635570210419636
[12] Bosilj, N., & Jurinjak, I. (2009). The Role of Knowledge Management in Mobile Marketing. *Journal of Information and Organizational Sciences*, *33*(2), 231–241.
[13] Boukis, A. (2019). Exploring the implications of blockchain technology for brand–consumer relationships: A future research agenda. *Journal of Product & Brand Management*, *29*(3), 307–320. https://doi.org/10.1108/JPBM-03-2018-1780
[14] Carvalho, R. B., & Ferreira, M. (2001). Using information technology to support knowledge conversion processes. *Inf. Res.* https://www.semanticscholar.org/paper/Using-information-technology-to-support-knowledge-Carvalho-Ferreira/ee712801a0c6dd5c0d46dc0e1be4172607b0eafc
[15] Chaffey, D., & Ellis-Chadwick, F. (2022). *Digital Marketing* (8th edition). Pearson.
[16] Chaudhary, K., & Alam, M. (2022). *Big Data Analytics: Digital Marketing and Decision-Making* (1st Edition). Auerbach Publications.
[17] Consoli, D., & Musso, F. (2010). *Marketing 2.0: A New Marketing Strategy* (SSRN Scholarly Paper 2467259). https://papers.ssrn.com/abstract=2467259
[18] Dalkir, K. (2017). *Knowledge Management in Theory and Practice, third edition*. MIT Press.
[19] Dash, G., Kiefer, K., & Paul, J. (2021). Marketing-to-Millennials: Marketing 4.0, customer satisfaction and purchase intention. *Journal of Business Research*, *122*, 608–620. https://doi.org/10.1016/j.jbusres.2020.10.016
[20] Davenport, T., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, *48*(1), 24–42. https://doi.org/10.1007/s11747-019-00696-0
[21] De Hoog, R. (2009). Knowledge Management: From idea to a discipline. In *Knowledge Management, Organizational Intelligence And Learning, And Complexity—Volume III; D. L. Kiel, Editor* (pp. 163–178). Eolss Publishers Co. Ltd.
[22] Dobrinić, D. (Ed.). (2011). *Marketing i baze podataka*. Fakultet organizacije i informatike. https://webknjizara.hr/proizvod/marketing-i-baze-podataka-damir-dobrinic/
[23] Dobrinić, D., & Gregurec, I. (2016). *Integrirani marketing*. Fakultet organizacije i informatike.

[24] Dung, D. H., & Lam, V. S. (2017). *SMES in the age of digital transformation: How predictive marketing can boost competitiveness of enterprises*. https://epub.vgu.edu.vn/handle/dlibvgu/193
[25] Eren, E., & Erdoğmuş, İ. E. (2004). KNOWLEDGE MANAGEMENT AND DATABASE MARKETING APPLICATIONS. *Doğuş Üniversitesi Dergisi*, *5*(1), Article 1.
[26] Erragcha, N., & Romdhane, R. (2014). New Faces of Marketing In The Era of The Web: From Marketing 1.0 To Marketing 3.0. *Journal of Research in Marketing*, *2*(2), 137. DOI: 10.17722/jorm.v2i2.46
[27] Fakhar Manesh, M., Pellegrini, M. M., Marzi, G., & Dabic, M. (2021). Knowledge Management in the Fourth Industrial Revolution: Mapping the Literature and Scoping Future Avenues. *IEEE Transactions on Engineering Management*, *68*(1), 289–300. https://doi.org/10.1109/TEM.2019.2963489
[28] Fuciu, M., & Dumitrescu, L. (2018). From Marketing 1.0 To Marketing 4.0 – The Evolution of the Marketing Concept in the Context of the 21 ST Century. *International Conference KNOWLEDGE-BASED ORGANIZATION*, *24*(2), 43–48. https://doi.org/10.1515/kbo-2018-0064
[29] García-Murillo, M., & Annabi, H. (2002). Customer knowledge management. *Journal of the Operational Research Society*, *53*(8), 875–884. https://doi.org/10.1057/palgrave.jors.2601365
[30] Garrido-Moreno, A., Lockett, N., & Garcia-Morales, V. (2015). Exploring the role of knowledge management practices in fostering customer relationship management as a catalyst of marketing innovation. *Baltic Journal of Management*, *10*(4), 393–412. https://doi.org/10.1108/BJM-10-2014-0166
[31] Gebert, H., Geib, M., Kolbe, L., & Brenner, W. (2003). Knowledge-enabled customer relationship management: Integrating customer relationship management and knowledge management concepts[1]. *Journal of Knowledge Management*, *7*(5), 107–123. https://doi.org/10.1108/13673270310505421
[32] Graesch, J. P., Hensel-Börner, S., & Henseler, J. (2020). Information technology and marketing: An important partnership for decades. *Industrial Management & Data Systems*, *121*(1), Article 1. https://doi.org/10.1108/IMDS-08-2020-0510
[33] Hanvanich, S., Dröge, C., & Calantone, R. (2003). Reconceptualizing the meaning and domain of marketing knowledge. *Journal of Knowledge Management*, *7*(4), 124–135. https://doi.org/10.1108/13673270310492994
[34] Henriquez, M., Herd, A., Danènas, P., Dilijonas, D., & Ontiveros, J. (2023). CLARK: Building Conversational Intelligence for Knowledge Management in the Space Domain. *European Conference on Knowledge Management*, *24*(1), Article 1. https://doi.org/10.34190/eckm.24.1.1792
[35] Hermina, N., Rahma, Y. D., & Gusnia, A. R. (2022). Marketing 5.0 and consumer behavior of the millennial (Gen Z) generation as business performance boosting on Covid-19 Pandemic-Case study: SMEs in west Java. *Central ASIA and The Caucasus*, *23*(1), 3732–3744.
[36] Igbinovia, M. O., & Ikenwe, I. J. (2017). Knowledge management: Processes and systems. *Information Impact: Journal of Information and Knowledge Management, 8*(3), Article 3. https://doi.org/10.4314/iijikm.v8i3.3
[37] Iqbal, U. (2023). From Knowledge Management to Intelligence Engineering—A practical approach to building AI inside the law-firm using open-source Large Language Models. *Proceedings of the Third International Workshop on Artificial Intel-Ligence and Intelligent Assistance for Legal Professionals in the Digital Workplace (LegalAIIA 2023)*, *3423*, 49–57. https://ceur-ws.org/Vol-3423/paper5.pdf

[38] Jara, A. J., Parra, M. C., & Skarmeta, A. F. (2012). Marketing 4.0: A New Value Added to the Marketing through the Internet of Things. *2012 Sixth International Conference on Innovative Mobile and Internet Services in Ubiquitous Computing*, 852–857. https://doi.org/10.1109/IMIS.2012.203

[39] Jaziri, D. (2019). The advent of customer experiential knowledge management approach (CEKM): The integration of offline & online experiential knowledge. *Journal of Business Research*, *94*, 241–256. https://doi.org/10.1016/j.jbusres.2018.05.029

[40] Kamel Boulos, M. N., & Wheeler, S. (2007). The emerging Web 2.0 social software: An enabling suite of sociable technologies in health and health care education1. *Health Information & Libraries Journal*, *24*(1), 2–23. https://doi.org/10.1111/j.1471-1842.2007.00701.x

[41] Khosravi, A., Hussin, A., & Dahlan, H. M. (2017). *Toward a survey instrument for investigating customer knowledge management in software companies*. https://www.semanticscholar.org/paper/Toward-a-survey-instrument-for-investigating-in-Khosravi-Hussin/fc4b85b1584bb123e6f8934be27eeb19286c02db

[42] Kim, H., & Kim, Y. (2001). Rationalizing the customer service process. *Business Process Management Journal*, *7*(2), 139–156. https://doi.org/10.1108/14637150110389713

[43] Kingsnorth, S. (2022). *The Digital Marketing Handbook: Deliver Powerful Digital Campaigns* (1st edition). Kogan Page.

[44] Kopalle, P. K., Gangwar, M., Kaplan, A., Ramachandran, D., Reinartz, W., & Rindfleisch, A. (2022). Examining artificial intelligence (AI) technologies in marketing via a global lens: Current trends and future research opportunities. *International Journal of Research in Marketing*, *39*(2), 522–540. https://doi.org/10.1016/j.ijresmar.2021.11.002

[45] Kotler, P., Kartajaya, H., & Setiawan, I. (2010). *Marketing 3.0: From Products to Customers to the Human Spirit* (1st edition). Wiley.

[46] Kotler, P., Kartajaya, H., & Setiawan, I. (2021). *Marketing 5.0: Technology for Humanity*. John Wiley & Sons.

[47] Lovrenčić, S. (2022). Support for Knowledge Management Processes with Blockchain Technology. *Proceedings of the 6th International Scientific Conference ITEMA 2022 - Recent Advances in Information Technology, Tourism, Economics, Management and Agriculture*, 1–7.

[48] Lovrenčić, S., & Sekovanić, V. (2019). Knowledge Management in Disruptive Times. *Proceedings of the 3rd International Scientific Conference EMAN – Economics & Management: How to Cope with Disrupted Times*, 373–381.

[49] Lucy. (2023). *Who can Lucy help—Knowledge Management Solution Across the Organization*. https://www.lucy.ai/enterprise-knowledge-management-for-companies

[50] Macnamara, J., Lwin, M., Adi, A., & Zerfass, A. (2016). 'PESO' media strategy shifts to 'SOEP': Opportunities and ethical dilemmas. *Public Relations Review*, *42*(3), 377–385. https://doi.org/10.1016/j.pubrev.2016.03.001

[51] Mcinerney, C., & Koenig, M. (2011). Knowledge Management (KM) Processes in Organizations: Theoretical Foundations and Practice. In *Synthesis Lectures on Information Concepts, Retrieval, and Services* (Vol. 3). https://doi.org/10.2200/S00323ED1V01Y201012ICR018

[52] Melović, B., Dabić, M., Vukčević, M., Ćirović, D., & Backović, T. (2021). Strategic business decision making: The use and relevance of marketing metrics and knowledge management. *Journal of Knowledge Management*, *25*(11), 175–202. https://doi.org/10.1108/JKM-10-2020-0764

[53] Meng, A. T. G., & Sidin, S. (2020). The Effect of Expectations and Service Quality on Customer Experience in the Marketing 3.0 Paradigm. *Journal of Marketing Advances and Practices*, *2*(2), 1–20.
[54] Migdadi, M. M. (2020). Knowledge management, customer relationship management and innovation capabilities. *Journal of Business & Industrial Marketing*, *36*(1), 111–124. https://doi.org/10.1108/JBIM-12-2019-0504
[55] Muniz, E. C. L., Dandolini, G. A., Biz, A. A., & Ribeiro, A. C. (2020). Customer knowledge management and smart tourism destinations: A framework for the smart management of the tourist experience – SMARTUR. *Journal of Knowledge Management*, *25*(5), 1336–1361. https://doi.org/10.1108/JKM-07-2020-0529
[56] Pachler, N., & Daly, C. (2009). Narrative and learning with Web 2.0 technologies: Towards a research agenda. *Journal of Computer Assisted Learning*, *25*(1), 6–18. https://doi.org/10.1111/j.1365-2729.2008.00303.x
[57] Paroutis, S., & Al Saleh, A. (2009). Determinants of knowledge sharing using Web 2.0 technologies. *Journal of Knowledge Management*, *13*(4), 52–63. https://doi.org/10.1108/13673270910971824
[58] Prabhu, D. (2016). APPLICATION OF WEB 2.0 AND WEB 3.0: AN OVERVIEW. *International Journal of Research in Library Science (IJRLS)*, *2*(1), 54–62.
[59] Romano Jr., N. (2000). Customer Relations Management in Information Systems Research. *AMCIS 2000 Proceedings*. https://aisel.aisnet.org/amcis2000/17
[60] Rot, A., & Sobinska, M. (2018). The Potential of the Internet of Things in Knowledge Management System. *Position Papers of the 2018 Federated Conference on Computer Science and Information Systems, 16*, 63–68. https://doi.org/10.15439/2018F379
[61] Rowley, J. (2002). Reflections on customer knowledge management in e-business. *Qualitative Market Research: An International Journal*, *5*(4), 268–280. https://doi.org/10.1108/13522750210443227
[62] Rowley, J. (2004). Partnering paradigms? Knowledge management and relationship marketing. *Industrial Management & Data Systems*, *104*(2), 149–157. https://doi.org/10.1108/02635570410522125
[63] Schmaltz, R., Hagenhoff, S., & Kaspar, C. (2004, April). Information Technology Support for Knowledge Management in Cooperations. *The Fifth European Conference on Organizational Knowledge, Learning, and Capabilities*. https://warwick.ac.uk/fac/soc/wbs/conf/olkc/archive/oklc5/papers/l-1_schmaltz.pdf
[64] Shabbir, M. Q., & Gardezi, S. B. W. (2020). Application of big data analytics and organizational performance: The mediating role of knowledge management practices. *Journal of Big Data*, *7*(1), 47. https://doi.org/10.1186/s40537-020-00317-6
[65] Shaw, M. J., Subramaniam, C., Tan, G. W., & Welge, M. E. (2001). Knowledge management and data mining for marketing. *Decision Support Systems*, *31*(1), 127–137. https://doi.org/10.1016/S0167-9236(00)00123-8
[66] Shrestha, B., Halgamuge, M. N., & Treiblmaier, H. (2020). Using Blockchain for Online Multimedia Management: Characteristics of Existing Platforms. In H. Treiblmaier & T. Clohessy (Eds.), *Blockchain and Distributed Ledger Technology Use Cases: Applications and Lessons Learned* (pp. 289–303). Springer International Publishing. https://doi.org/10.1007/978-3-030-44337-5_14
[67] Silwattananusarn, T., & Tuamsuk, K. (2012). Data Mining and Its Applications for Knowledge Management: A Literature Review from 2007 to 2012. *International Journal of Data Mining & Knowledge Management Process (IJDKP)*, *2*(5), 13–24. https://doi.org/10.48550/arXiv.1210.2872
[68] Sima, E. (2021). Managing a brand with a vision to marketing 5.0. *MATEC Web of Conferences*, *343*, 07015. https://doi.org/10.1051/matecconf/202134307015

[69] Stallone, V., Wetzels, M., & Klaas, M. (2021). Applications of Blockchain Technology in marketing—A systematic review of marketing technology companies. *Blockchain: Research and Applications*, *2*(3), 100023. https://doi.org/10.1016/j.bcra.2021.100023

[70] Stankosky, M. A. (2005). Advances in Knowledge Management: University Research Toward an Academic Discipline. In *Creating the Discipline of Knowledge Management* (pp. 1–14). Routledge.

[71] Stefanou, C. J., Sarmaniotis, C., & Stafyla, A. (2003). CRM and customer-centric knowledge management: An empirical research. *Business Process Management Journal*, *9*(5), 617–634. https://doi.org/10.1108/14637150310496721

[72] Vassileva, B. (2017). Marketing 4.0: How Technologies Transform Marketing Organization. *Óbuda University E-Bulletin*, *7*, 47–56.

[73] Waheed, A., Dhupia, B., & Mesfer Aldossary, S. (2023). Recapitulation Web 3.0: Architecture, Features and Technologies, Opportunities and Challenges. *Intelligent Automation & Soft Computing*, *37*(2), 1609–1620. https://doi.org/10.32604/iasc.2023.037539

[74] Wei, C. C., & Yeganeh, M. (2013). The Influence Of Information Technology On The Knowledge Management Process. *Journal of Knowledge Management Practice*, *14*(1). http://www.tlainc.com/articl327.htm

[75] Wongmonta, S. (2021). Marketing 5.0: The Era of Technology for Humanity with a Collaboration of Humans and Machines. *Nimitmai Review Journal*, *4*(1), Article 1.

[76] Yuman, Y., & Goyal, D. S. (2022). Knowledge Management using IoT-Blockchain Technology: State of the Art. *International Journal of Electrical and Electronics Research (IJEER)*, *10*(2), 183–189. https://doi.org/10.37391/IJEER.100223

[77] Zebal, M., Ferdous, A., & Chambers, C. (2019). An integrated model of marketing knowledge – a tacit knowledge perspective. *Journal of Research in Marketing and Entrepreneurship*, *21*(1), 2–18. https://doi.org/10.1108/JRME-03-2018-0018

Review article / Pregledni rad

FOREST RECREATION TOURISM - HEALTH PREVENTION AND WELFARE FOR CYBER SOCIETY
PART 1 FOREST GREEN SYSTEM

KRASIMIRA STANEVA
University of Forestry
Faculty of Ecology and Landscape architecture
10 Kl. Ohridski Blvd., 1756 Sofia, Bulgaria
bagg.ks@gmail.com

MARTIN MARINOV
University of Library Studies and Information Technologies (UniBit)
martinemarinov95@gmail.com

ABSTRACT

Forest recreation tourism presented itself as traditional and innovative solution for health prevention. Combination between different natural elements brings us a unique possibility for sustainability welfare of internet society members. The synergy of climate, relief, landscape, waters and biodiversity becomes the main powerful mechanism for public health prevention. Obviously, the health is a state of complete physical, mental and social well-being and it is an essential component of national security.

The aim of research has been to describe natural recreation resources in forest ecosystem and estimate their healing function of human. The functioning of cyberspace is associated with non-ionizing electromagnetic radiations that have a significant impact on humans. Two different target groups have been examined with their main physiological parameters, psychoemotional comfort and social welfare in the past 2022 year. Our project offers forest education events, forest baths, forest therapy, forest adventure places and forest plants trials.

The main results are the strong positive healing effect of forest recreational tourism on the project participants. One more value is developing of very new forest culture with focus on healing function of the specific forest ecosystem and connecting to public health security. The social well-being, which is related to health, affects the overall performance of the individual in cyber society.

KEYWORDS: forest recreation, cyber society, health prevention, welfare, national security

1. INTRODUCTION

Cyberspace as a global network of interconnected information and communication systems operates through its physical infrastructure—hardware, routers, switches, hubs,

telecommunications networks, computer systems, and all Internet-connected devices, including medical devices. The impact of digital connectivity on socio-economic development is multidirectional. For the economy, it provides access to existing markets and creates new ones. In the business sphere, an efficient connection is made between human resources and the resources needed by the production process, and in the social sphere, publicly accessible services are provided through online portals.

The functioning of cyberspace is associated with non-ionizing electromagnetic radiations that have a significant impact on humans. The growing application of wireless devices and sensors leave their negative imprint on the environment in which the life cycle of each one of us takes place. The inevitable digital transformation also provokes the rapid development of a cyber society, in which each one of us is, in a certain sense, a participant.

In our study, public health of cyber society members has a special status. Critical information related to the health and safety of human life that creates, manages and controls all processes related to material production is subject to cyber protection. On the other hand, it is particularly valuable as a resource for analyzing how the digital transformation process affects the health of its participants.

Research in this area marked serious progress in the period 1967-1987. The sources of radio frequency fields play an essential role in this. There are serious arguments in the literature about their possible negative biological effects [Aldrich, T.; Easterly, C. et al, 1988; Cahill, D., Elder, J, 1984; Taylor, J. 1984].

Today, research is expanding to public health prevention [Augner, Cr., Hacker, G.W.; et al, 2010].

The uniqueness of cyberspace also implies innovative solutions to possible problems for its active participants. One possibility relates to the recreational function of forest ecosystems. Forest territories are multifunctional - they have sports, recreational, creative, educational, anti-stress and entertainment functions. The traditional forms of tourism, methodologically oriented and adapted to current health problems, are an intelligent opportunity for health prevention. In this connection, we consider the recreational potential of forest areas for health prevention and improving the quality of life of active participants in the cyber society.

2. DESIGN OF INVESTIGATION: AIM, OBJECT, DATABASE COLLECTION

The article presents the results of the activities of the project "No. NIS-1211 -27.04.2022 "Assessment of the opportunities of forest recreational tourism to improve the lives of active users of smart technologies", which aims to:

- To model and test in virtual space two forest recreational tourist destinations to restore the psycho-emotional comfort and health status of active users of smart technologies.

- To analyze the opportunities of forest recreational tourism to increase the quality of life of users of smart technologies.

In connection with the implementation of the set project task, 4 business trips were carried out by part of the team to the "Avramov" UOGS in the village of Yundola, where field measurements of the electromagnetic field were made in 17 experimental points /EP/. The information has been summarized and published [Staneva. K. 2022; Staneva. K., M. Marinov 2021; Станева, К., Гарванова, М. et al. 2020].

The research objective in the presented article has been to evaluate the natural resources for recreation in forest green ecosystems in the context of their application in forest recreation tourism.

The object

The studied sites are Yundola and Petrohan Training and Experimental Forest Ranges, which are located in ecologically clean areas.

Data collection and research methods

The collection of data on the quality of environmental components, climate, electromagnetic pollution and green forestry ecosystem was achieved through a field survey, literature sources and archival resources in forest enterprices.

The recreation potential of forest green system is determined according to a methodology developed by experts from the Bulgarian Geomedicine and Geotherapy Association. It is based on a detailed characterization of the climate resource and a medico-biological assessment of climate-forming factors, the landscape, geomedical assessment of the environment and physiological impact of the environment on human health.

3. FINDING AND DISCUSSION

For the creation of a specialized forest recreational tourism product, it is necessary to apply the natural resources that are cultivated in the forest territories and the natural, wild environment associated with them. An important condition for full-fledged outdoor recreation is to take place in preserved natural ecosystems, which are in forest areas. The recreational potential of a given area is measured by the quality of the atmospheric air, climatic conditions, presence of temperature comfort, diverse relief and water resources and natural habitats. Species diversity in forest areas is an invaluable resource in integral suitability assessment.

3.1. FOREST RECREATION POTENTIAL OF YUNDOLA TRAINING AND EXPERIMENTAL FOREST RANGE

The Yundola training and experimental forest range (UOGS) is located on the border between the Eastern Rila and the Rhodopes, 16 km from the town of Velingrad.

The topography profile is typically mountainous. The average altitude is 1400 m and the terrain is suitable for loads of different intensity.

Yundola is a climate resort of national resort since 1967. The studied area has the following characteristic /according to regulation N14-State Gazette. No. 79 of October 13, 1987, amended DV. No. 70 of August 10, 2004/: a physiologically favorable thermal characteristic of the meteorological environment; there is not industrial pollution, and the concentration of harmful aerosols, gases and dust not exceed 25% of the hygiene standards; the area is at least above the level of general inversion cloudiness and outside of local temperature inversions; suitable landscape conditions; the duration of sunshine is at least 2200 hours per year; the intensity of ultraviolet radiation with a length of less than 315 nanometers is at least close to the normal for a certain area; the concentration of light air ions is at least over 1000 units/cubic cm in the mountainous areas and over 500 units/cubic cm in the plains; no funnel-shaped currents; the physical-geographical conditions favor the formation of breeze circulation; the duration of the snow cover at least more than 100 days per year.

Clean air and a favorable climate are prerequisites for applying climate-therapeutic procedures. Diseases of the respiratory organs (including bronchial asthma), diseases of the renal-vascular system, disorders of the nervous system, allergic and endocrine diseases are well affected.

According to the climatic zoning of Bulgaria, the territory of UOGS "G. Art. Avramov" is located in the Transitional-Continental climate sub-region, falling into the Mid-Mountain part of the Mountain Climate Region. The average annual relative humidity is relatively high - 78%. In the study area, the annual number of days with low humidity is 12, while the number of days with relative humidity above 80% is 100. The rainfall regime is characterized by two maxima in May (89.3 mm) and November (58.6 mm) and two minima in September (41.9 mm) and February (45.1 mm). The seasonal dynamics outlined in this way are characteristic of the Transitional climatic region.

Thermal conditions in the considered territory are characterized by well-defined seasonality due to differences in the radiation balance in winter and summer. The amplitude between the average maximum and minimum air temperature is greatest in the August-September period, i.e., towards the end of the growing season, the most extreme temperature conditions are recorded.

Forest Green system

The University training base is at 1000-1800 m above sea leveland covers 5190,6 ha, 4853,8 ha – afforested area. The lowest point of the area is the valley line of Dulboki Dol and Lyuta Reka (1030 m altitude), and the highest point is Arapchal Peak (1834 m). The average altitude of the wood productive forest area is 1460 m. The tree species are represented by: Scots Pine - 1935,3 ha (or 40% of the forest fund); Norway Spruce - 1427,7 ha (30%); Silver Fir - 1267,8 ha (26%); Beech - 166 ha (3%), etc. The average age of the stands is 75 years. The stands are exclusively coniferous, consisting mainly of Scots Pine, Norway Spruce and Silver Fir. The percentage of the broadleaved species is insignificant, mainly Beech and Sessile Oak. The growth conditions are typical of coniferous stands and allow the establishment of various training and demonstration sites and experimental areas. [3] The slopes of the forests in the area are covered with juniper plantations, and the Rila and Rhodope mountains protect the area from strong winds.

Figure 1. Yundola training and experimental forest range

Source: https://ltu.bg/en/university/training-and-sport-centres/training-centres/yundola-training-and-experimental-forest-range

3.2. FOREST RECREATION POTENTIAL OF PETROHAN TRAINING AND EXPERIMENTAL FOREST RANGE

The Petrohan Training and Experimental Forest Range (UOGS), Burzia village, has a 120-year history. Its special status, as a center for educational, experimental and scientific research activity dates back to 1928. It is located on the northeastern slopes of the Western Balkan Mountains. The range located 6 km from Berkovitsa town. Its total area is 7192 ha.

The topography profile is typically mountainous, steep, with deeply connected river valleys and steep secondary ridges. The lowest point in the area is 350 m above sea level, and the highest 1900 m. The relief the mountainous southern part is characterized by large elevations, steep and many steep to rugged slopes and rugged terrain. The Berkoviza section of the Stara planina is the highest ridge in the region under study.

The Petrohan Training and Experimental Forest Range is situated in the Northern Bulgarian climatic zone with a moderate continental climate. The mountainous climatic region is characterized by lower temperatures, small temperature amplitude, high cloudiness and precipitation, long and persistent snow cover, atmospheric low, high pressure, relative humidity, strong winds. It is characterized by severely cold and windy winters, warm summers, long autumns, warmer autumns. During the winter months, the average daily temperature minimum is +1ºC and maximum + 7ºC; in July, respectively, the average daily minimum is +17ºC and maximum +30ºC. Rainfall in January is 77 mm, and in July - 31 mm.

Fresh air and a favorable climate are prerequisites for applying outdoor recreation practices.
The water resource in the area is particularly valuable – thermal spring (31ºC) and mountain river. The Burziya River rises under Todorini Kukli peak and flows in a deep and wooded valley near the village of Burziya. Bercovitsa is national balneological resort and an element of Bulgarian SPA destiantions, named Stara planina SPA tourism destination. M ineral water is hypothermal (32ºC), pH 9.4 with a total mineralization of 0.29 g/l, containing hydrocarbonate, sulfate, sodium and fluoride ions; colloidal meta silicic acid [https://www.tourism.government.bg/bg/spa-destinations/6576/6577/].

Forest Green system

The Petrohan forest is one of the earliest measured and managed forests in the country. Its first management plan was implemented in 1893. The predominant tree species is the Beech, growing on brown forest soils – dark and transitional. It occupies 81,7% of the range afforested area. The Scots Pine occupies 5,8%, the Norway spruce – 4,0%, the Hornbeam – 3,7%, other broadleaved tree species–2,0% of the afforested area.
Forests designated for protective functions represent a high percentage of the afforested area - 74,4 %. They are located in a water supply area.

A selection forest range has been established on an area of 4,5 %.
Among the forest tree species, the most significant is the presence of the Petrohan beech plantations, which are among the best in Europe. They are unique in their performance and multifunctional purpose. A large part of the forest area, 88.5%, falls in the middle mountain belt of beech and coniferous forests (600-1800 m), and the distribution by sub-belts is as follows:

- low mountain subbelt (600- 1000 m above sea level) 37.7%;
- mid-mountain subbelt (1001-1500 m a.s.l.) 44.7%;

- mountainous subbelt (1501-1800 m above sea level) 6.1%.

The rest of area falls in the Lower plain-hilly and hilly-foothill belt of oak forests 11.5%.

The unique combination of climate, landscape and green system makes it possible to have a full outdoor recreation. This process is an essential element of health prevention and social stability.

Figure 2. Petrohan training and experimental forest range

Source: LTU (2023). https://ltu.bg/en/university/training-and-sport-centres/training-centres/petrohan-training-and-experimental-forest-range-the-village-of-barziya, downloaded: [July, 9th 2023]

4. DISCUSSION

In order to assess the suitability of the recreation area according to the applied methodology, the data on average monthly and average monthly minimum temperature were analyzed, which are directly related to the determination of the length of stay outdoors in a natural environment. In combination with applicable recreational requirements applied in some countries, climatic conditions, sanitary conditions (SO_2 and NO_2 content), electromagnetic field (non-ionizing radiation) and ambient air quality were evaluated in the two studied sites [De Freitas, C. 2003]. The conditions in the green forest system are certainly beneficial from a physiological point of view.

The mountain-valley breeze, from the forested mountain slopes and valleys, carries a large amount of negative ions into the populated areas. The suitable climate is favorable for year-round use. There is no industrial production on the territory. The content of sulfur dioxide, nitrogen dioxide, fine dust particles and lead in the atmospheric air is within the norm according to the maximum allowable concentrations of harmful substances in the atmospheric air of the populated areas of the Ministry of the Environment.

The modeled landscape, an element of the modern stratified relief of Stara Planina and Rodopes mauntain is suitable for conducting hikes with different degrees of physical exertion for the participants. The positive assessment of the landscape is associated with the presence of medicinal and healing properties of the vegetation - high phytoncides, high ionization of the air, a favorable microclimate (compared to that of the city of Troyan) and a high aesthetic

impact on the psycho-emotional state of the person. The presence of rugged relief, diverse open and panoramic areas with suitable vegetation are an additional favorable factor for the synergistic impact of the natural resources discussed.

5. CONCLUSION

The natural conditions in the studied sites are suitable for the development of recreational tourism. Forest areas are universal locations for team building events of members of the cyber society. The presence of diverse tree species located in different mountain belts is a prerequisite for their inclusion in restorative procedures and practices for tourists who are active members of the cyber society. The favorable combination of climatic conditions, landscape forms, water resources and superb green forest ecosystem are a valuable recreational resource. Combined with the circumstance, that the two studied objects are elements of the national resort list are an additional argument in support of the position that the Yundola and Burzia Training and Experimental Forest Ranges have a unique forest recreational potential. Their vitality as an outdoor recreation center should be purposefully developed as part of a national health prevention program.

REFERENCES

[1] Станева, К.; Гарванова, М.; Гарванов, Ив.; Маринов, М. (2020). Приложение на горския рекреационен туризъм в управление на стреса, причинен от GSM., Сборник с доклади от Годишна университетска научна конференция, 28-29 май 2020 г., НВУ "Васил Левски". Велико Търново, Издателски комплекс на НВУ "Васил Левски", pp 1448-1456, ISSN 2367-7481.

[2] Aldrich, T.; Easterly, C.; Galley, P.; Hamilton, C. (1988). Bioelectromagnetic Effects of EMP: Preliminary Findings, Oak Ridge National Laboratory, ORNL/TM-10784 (1988).

[3] Augner, Cr.; Hacker, G.W.; et al, (2010) . Effects of Exposure to GSM Mobile Phone Base Station Signals on Salivary Cortisol, Alpha-Amylase, and Immunoglobulin A. Biomedical and Environmental Sciences, Vol. 23, Issue 3, pp 199-207 p., DOI: 10.1016/S0895-3988(10)60053-0 (2008).

[4] Cahill, D.; Elder, J, editors (1984). Biological Effects of Radiofrequency Radiation, U.S. Environmental Protection Agency, EPA-600/8-83-026F (1984)

[5] De Freitas, C. (2003)] Tourism Climatology: Evaluating Environmental Information for Decision Making and Business Planning in the Recreation and Tourism Sector. International Journal of Biometeorology, 48, 45-54. http://dx.doi.org/10.1007/s00484-003-0177-z

[6] Kostoff RN. Adverse Effects of Wireless Radiation (2019). http://hdl.handle.net/1853/61946. [July, 10th 2023]

[7] Nieden A,; Dietz C.; Eikmann T.; Kieferq, J.; Herr CEW (2009). Physicians appeals on the dangers of mobile communication--what is the evidence? Assessment of public Adverse Effects of Wireless Radiation. International journal of hygiene and environmental health. 212(6):576-87 (2009).

[8] Patrick, E.; Vault, W. (1990). Bioelectromagnetic Effects of the Electromagnetic Pulse (EMP) HDL-TL-90-2, pp 1-18. https://apps.dtic.mil/sti/citations/ADA221552 downloaded: [July, 9th 2023]

[9] Staneva. K (2022). Well-being tourism as a health promotion for employee in the IT sector. CroDiM, Vol. 5, No. 1, 2022, pp 21-28. e-ISSN 2584-7236

[10] Staneva. K.; M. Marinov (2021). Impact of electromagnetic fields on information security and public health. Knowledge-International Journal, 53(3), pp 473–479. ISSN 2545-4439 https://ikm.mk/ojs/index.php/kij/article/view/5447
[11] Taylor, J. (1984). Biological Effects of the Electromagnetic Pulse, Harry Diamond Laboratories, HDL SR-90-3
[12] Walter, J. (2023). How an EMP Attack Would Affect Humans. https://www.superprepper.com/emp-effects-on-humans/, downloaded: [July, 9th 2023]
[13] LTU (2023). https://ltu.bg/en/university/training-and-sport-centres/training-centres/petrohan-training-and-experimental-forest-range-the-village-of-barziya, downloaded: [July, 9th 2023]
[14] LTU (2023). https://ltu.bg/en/university/training-and-sport-centres/training-centres/yundola-training-and-experimental-forest-range downloaded: [July, 9th 2023]
[15] Tourism Government (2023). https://www.tourism.government.bg/bg/spa-destinations/6576/6577/. Downloaded: [July, 11th 2023]

The study was funded with the assistance of the project "No. NIS-1211 -27.04.2022 "Assessment of the opportunities of forest recreational tourism to improve the lives of active users of smart technologies"- University of Forestry

Review article / Pregledni rad

DRUŠTVENA ODGOVORNOST, SNAGA BRANDA I PEROFRMANSE PODUZEĆA

ANITA TALAJA
Sveučilište u Splitu
Ekonomski fakultet
Cvite Fiskovića 5, 21 000 Split, Hrvatska
anita.talaja@efst.hr

SLAVKO ŠODAN
Sveučilište u Splitu
Ekonomski fakultet
Cvite Fiskovića 521 000 Split, Hrvatska
slavko.sodan@efst.hr

IVAN MERŠA
Sveučilište u Splitu
Ekonomski fakultet
Cvite Fiskovića 521 000 Split, Hrvatska

SAŽETAK

Cilj ovoga rada je prikazati važnost društveno odgovornog poslovanja poduzeća (DOP-a) u kontekstu tržišnog uspjeha, rasta performansi i snage branda. Poduzeća koja implementiraju DOP nadilaze standardne okvire tradicionalnog poslovanja te razmatrajući sadašnje i buduće društvene probleme uzimaju u obzir širi društveni okvir u kojem posluju. Međutim, jedan od razloga promjene DOP-a odnosi se i na pokušaj izdvajanja poduzeća od ostalih konkurenata kroz kreiranje bolje slike poduzeća i jačanje branda. Stoga ovaj rad analizira neke od potencijalnih pozitivnih učinaka koji bi mogli proizaći iz implementacije DOP-a. Empirijsko istraživanje provedeno je na uzorku velikih poduzeća koja posluju u Republici Hrvatskoj. Od 391 poduzeća obuhvaćenog osnovnim skupom, prikupljen je 31 ispravno popunjeni upitnik, što čini stopu povrata od 8%. Stata je korištena za obadu podataka i testiranje hipoteza. Rezultati su pokazali da ne postoji statistički značajna veza između razine DOP-a performansi poduzeća. Međutim, postoji pozitivna veza između društveno odgovorne marketinške aktivnosti i snage branda.

KLJUČNE RIJEČI: DOP, brand, društvena odgovornost, performanse poduzeća

1. UVOD

Iako su nedosljednosti u definiranja društvene odgovornosti poduzeća (DOP) donekle usporile razvoj tog kocepta [McWilliams, et al., 2006] i razumijevanje uzorka i posljedica procesa DOP-a [Orlitzky, et al., 2011], u ovom radu prihvatit ćemo stajalište društveno odgovorno poslovanje (DOP) odnosi na aktivnosti poduzeća koje promiču neko društveno dobro te nadilaze profitne

ciljeve i zakon [McWilliams i Siegel, 2001]. Dakle, društveno odgovorno poslovanje je prisutno je kada poduzeće, uz strogo propisane obveze, u sustav odlučivanja ugrađuje brigu za okoliš i društvo. Globalizacija i rastući pritisci interesno-utjecajnih skupina povećali su interes za koncept DOP-a [Rahbek i Pedersen, 2015]. Iako napori u kontekstu DOP-a mogu biti strateški, altruistični ili prisilni [Husted i Salazar, 2006], u većini situacija zahtjevi različitih interesno-utjecajnih skupina vode to toga da menadžeri dio resursa usmjere u DOP [McWilliams i Siegel, 2001]. DOP je model korporativnog upravljanja koji u obzir uzima interese različitih interesno-utjecajnih skupina [Sacconi, 2019]. DOP je višedimenzionalan, odnosi se na napore organizacija da se nose s različitim društvenim i ekološkim problemima i može uključivati različite inicijative, od onih koje pokušavaju ublažiti utjecaj industrijskih postrojenja i proizvodnih metoda na okoliš [Rondinelli i Berry 2000], preko uključivanja rodne ravnopravnosti u program DOP-a [Grosser, 2009], do marketinških inicijativa koje promiču društvenu dobrobit i koristi za okoliš [Roberts, 2003; Szmigin, et al., 2007]. Svrha ovog rada je analiza odnosa društveno odgovornog poslovanja i performansi poduzeća u kontekstu prihoda od prodaje i tržišnog udjela. Također, nastoje istražiti koristi društveno odgovornih marketinških aktivnosti.

2. KONCEPT DRUŠTVENE ODGOVORNOSTI

Tijekom 1970-ih poduzeća su počela voditi računa o višestrukim interesima zaposlenika, dobavljača i lokalnih zajednica, umjesto da se samo teži ostvarenju profita za dioničare. Konceptu DOP-a značajno je doprinio Odbor za ekonomski razvoj (CED) koji je u svojoj publikaciji pod nazivom Društvene odgovornosti poslovnih društava iz (1971) objavio da poslovanje funkcionira uz javnu suglasnost i da je njegova osnovna svrha konstruktivno služiti potrebama društva i na zadovoljstvo društva. Od poduzeća se tražilo da preuzmu veću odgovornost prema društvu i da poštuju širi raspon ljudskih prava i vrijednosti [Carrroll, 2008]. Tijekom 1980-ih, javlja se povećani za razmatranje poslovne etike i DOP-a. Osniva se glavna uprava za okoliš (1981) od strane Europske komisije, Svjetska komisija za okoliš (1983), a UN usvaja Montrealski protokol (1987). Tijekom 1990-ih mijenja se stav prema društvenoj odgovornosti i pristupu održivosti. Osniva se Europska agencija za okoliš (1990), u Rio de Janeiru je organiziran je summit UN-a na kojem se donosi Deklaracija o okolišu i razvoju (1992), a 1997. se usvaja Protokol iz Kyota [Latapí Agudelo, et al., 2019].

Od početka rasprave o društveno odgovornom poslovanju postoje zagovornici i protivnici ove ideje. Među kritičarima posebno se ističe Milton Friedman, dobitnik Nobelove nagrade za ekonomiju. Friedman je aktivnosti DOP-a vidio kao neprimjereno korištenje resursa poduzeća što rezultira neopravdanim trošenjem resursa za opći i društveni interes [Latapí Agudelo, et al., 2019]. Friedmanova ideja vodilja je da se poduzeća trebaju koncentrirati na ono što rade najbolje, a to je proizvodnja proizvoda i usluga na najučinkovitiji način, kako bi poslovanje bilo tržišno konkurentno. Smatrao je kako DOP smanjuje primarnu svrhu poduzeća. Friedmanova tvrdnja je da poduzeće koje ostvaruje profit pod pravednim uvjetima kroz redovito poslovanje predstavlja doprinos društvenoj dobrobiti, a pravednost je potrebno prepustiti političkom sustavu kao regulatoru moći.

Međutim, Friedmanovi argumenti zanemaruju nekoliko važnih pitanja. Prvo, granica između poslovne i političke vlasti nije tako oštra kao što Friedman pretpostavlja, poduzeća često lobiraju u pitanjima politike i imaju određeni utjecaj na donošenje novih propisa. Nadalje, treba uzeti u obzir poslovno iskorištavanje zajedničkih dobara, poput zraka, vode, zemlje i ljudi. Pri tom, povijesno gledano jasno je da politički propisi nisu uspjeli obuzdati navedene

eksploatacije. Ipak, različiti društveno-politički konteksti utječu na raspravu, na primjer, pokušava li se pronaći rješenje iz perspektive liberalne ekonomije ili koordinirane tržišne ekonomije [Aslaksen, et al., 2021]. Frankental (2001) pronalazi paradoks u tome što ne postoji direktor ili menadžer koji će priznati nedovoljnu angažiranost prema društvu, a upravo priznavanje pogrešaka i loših aktivnosti čini svrhu DOP-a. On smatra da DOP nema utjecaj na tržišnu vrijednost poduzeća i da rast vrijednosti poduzeća može biti jedina stvarna motivacija korporacijama da budu društveno odgovorna. Također smatra da se DOP koristi kao alat odnosa s javnošću te da služi kao marketinški trik.

Veza između ulaganja u DOP i financijskog povrata predmet je brojnih istraživanja. Tu se pojavljuje neriješeno pitanje uzročnosti financijskog uspjeha ulaganjem u DOP. Poduzeća se mogu suzdržavati od ulaganja u DOP iz straha da će oslabiti financijski učinak poslovanja, stvarajući tako nepotrebnu štetu za društvo i okoliš. Također, moguće je da poduzeća ulažu više nego što bi trebala nastojeći kapitalizirati raspoloženje javnosti, a da kasnije utvrde da su zapravo snizili vrijednost dioničarima. Prilikom donošenja odluke o ulaganju u DOP poduzeće ima mogućnost odabira više opcija, ovisno o mogućnostima pojedinog poduzeća. Na primjer, ekološke inicijative često dovode do izravnih ušteda i smanjenja troškova. Nadalje, navodi da društveno odgovorna ulaganja pored navedenih financijskih ušteda, dovode i do nižeg rizika poslovanja. Zaključuje da ulaganje u DOP, kako bi se ublažila prijetnja državnih regulacija u budućnosti, smanjuje rizik poslovanja i predstavlja kvalitetno potrošen kapital tog poduzeća. Međutim, ako poduzeće donira u dobrotvorne svrhe kako bi bilo privlačnije, korist se ostvaruje tako njega percipira boljim od drugih poduzeća na tom tržištu. Ali, ako sva poduzeća koriste sličnu strategiju onda je financijski učinak negativan, jer sva poduzeća sada imaju trošak, a bez inicijalnog ostvarenja prednosti [Pelosa, 2009].

Postoje mnogobrojna istraživanja koja pokazuju da DOP ima pozitivan utjecaj na zaposlenike. Zadovoljstvo zaposlenika možemo definirati kao emocionalnu vezanost za posao ili kao ugodno emocionalno stanje koje proizlazi iz rada. Dobro utvrđeni prediktor zadovoljstva poslom je podudarnost između vrijednosti zaposlenika i mogućnosti za ispunjenje tih vrijednosti na radnom mjestu. Postoji veliki broj istraživanja koja su pokazala da je DOP pozitivno vezan sa zadovoljstvom zaposlenika. Ovaj efekt je posebno jak kada zaposlenici vide da se praksa DOP-a odražava na unutarnje organizacijske vrijednosti, a ne vanjske promotivno vođene ciljeve. Također, povezanost DOP-a sa zadovoljstvom zaposlenika generalno ogleda se u sposobnosti smanjenja neusklađenost između onoga što zaposlenici imaju i onoga što trebaju ili žele. Stoga [Wisse, et al., 2018]. Međutim, ne reagiraju svi zaposlenici jednako na prakse DOP-a. Primjerice istraživanja su pokazala da je učinak DOP-a na zadovoljstvo zaposlenika je izraženiji za starije nego za mlađe zaposlenike, jer se praksa DOP-a bavi onim emocionalnim potrebama i ciljevima koji se postavljaju kao prioritet kada se buduća vremenska perspektiva ljudi smanji. Sukladno tome, zaključuje da primjena DOP-a može predstavljati atraktivan alat za organizacije kojima je cilj zadržati svoje starije zaposlenike. Ovo istraživanje objašnjava dobne razlike u društvenim aktivnostima i emocionalnoj zrelosti odraslih kroz promjene društvenih ciljeva kroz vrijeme. Prema istraživanju, društveni ciljevi mogu se općenito podijeliti na ine koji se odnose na instrumentalne svrhe i one povezane s emocionalnim značenjem. Kada pojedinci postanu svjesni vremenskog ograničenja, tada počinju davati prioritet emocionalno značajnim društvenim ciljevima, kao što su: intimnost, osjećaj društvene pripadnosti i posvećenost novim generacijama. Nasuprot tome, kada pojedinci percipiraju svoje buduće vrijeme bez ograničenja, daju prednost instrumentalnim ciljevima, kao što su stjecanje znanja, statusa i novca [Carstensen, 2006].

Marketing usmjeren općoj dobrobiti prema društvenim i ekološkim utjecajima koristi za dosezanje potrošača i tržišno pozicioniranje. Tijekom posljednjih desetljeća pojavljuje se sve više poduzeća koja usvajaju pojam marketinga opće dobrobiti te on postaje sve popularniji marketinški alat. Poduzeća koja ga primjenjuju u svom poslovanju uočila su njegovu dobrobit za poduzeće i društvo. Primarna svrha ove vrste marketinga je društvena korisnost. Promocija proizvoda ili usluga je u drugom planu, ali nije zanemarena. Marketing opće dobrobiti nadilazi stvaranje profita i uključuje probleme društva, jer polazi od toga da je teško pridobiti povjerenje potrošača sve dok se ne riješe društveni i ekološki problemi. Poduzeća koja teže DOP-u i marketingu opće dobrobiti zalažu se za opće dobro, podržavaju DOP inicijative i doprinose značajnim financijskim sredstvima neprofitnom sektoru [Glavočević i Radman Peša, 2013].

Većina istraživanja sugerira postojanje pozitivnog odnosa između marketinških aktivnosti koje su usmjerene prema DOP-u i stava potrošača o tom poduzeću i njegovim proizvodima. Kada poduzeće svojim marketinškim aktivnostima uspije poistovjetiti potrošača sa svojim DOP ciljevima to može uvelike poboljšati imidž marke (branda) i stvoriti lojalnog kupca. Primjerice, istraživanje su pokazala kako je većina ispitanika spremna platiti višu cijenu za ekološki prihvatljivu elektroniku, ali samo ako razlika ucijeni nije značajna. Nadalje, istraživanja su pokazala i da cijena ne predstavlja bitnu barijeru prilikom kupovine voća i povrća, odnosno da su kupci spremni su platiti višu cijenu za organske proizvode [Agarwal, 2012; Nixon et al., 2007].

3. EMPIRIJSKA ANALIZA

Podaci su prikupljeni uz pomoć anketnog upitnika koji je oblikovan na temelju prijašnjih istraživanja [Osmanagić Bedenik i Labaš, 2011] te se sastoji od pitanja zatvorenog tipa. Pitanja se odnose na opće podatke o poduzeću (vlasnička struktura, primarna djelatnost, udio izvoza i starost poduzeća), uspješnost poduzeća u danim kategorijama, te provedbu DOP-a u poduzeću. Osnovni skup se sastoji od 391 velikog poduzeća koje posluje u Republici Hrvatskoj. Prikupljen je 31 uredno popunjen upitnik, što čini stopu povrata od 7,93%. Za obradu podataka korišteni su softveri Stata i Tableau.

Od ukupnog broja poduzeća koja su sudjelovala u istraživanju, 14 ili 45,1% poduzeća je u privatnom stranom vlasništvu, 11 ili 35,5% privatnom domaćem vlasništvu, a 6 ili 19,4% u državnom vlasništvu. Najveći broj poduzeća koja su odgovorila na anketu bavi se prerađivačkom djelatnosti 19,3% te 13% maloprodajom i veleprodajom. Podjednako su zastupljena poduzeća koja se bave građevinom, informacijskim tehnologijama te prijevozom u pojedinačnim udjelima od 9,7%. Najmanje su zastupljena poduzeća koja se bave telekomunikacijama 6,4% i financijskim poslovanjem 3,2%. Iz tablice je vidljivo da 35,5% poduzeća izvozi do 25% vrijednosti od ukupne prodaje, njih 22,5% izvozi do 50% ukupne vrijednosti prodaje, 13% izvozi preko 50% od ukupne vrijednosti prodaje te 29% poduzeća prodaje isključivo na domaćem tržištu. Većina anketiranih poduzeća posluje dulje od 20 godina, odnosno njih 87%, dok njih 13% posluje između 10 i 20 godina. Prikaz 1 pokazuje kumulativ DOP mjera koje poduzeća koriste u svom poslovanju.

Prikaz 1. DOP mjere koje poduzeće primjenjuju u svom poslovanju

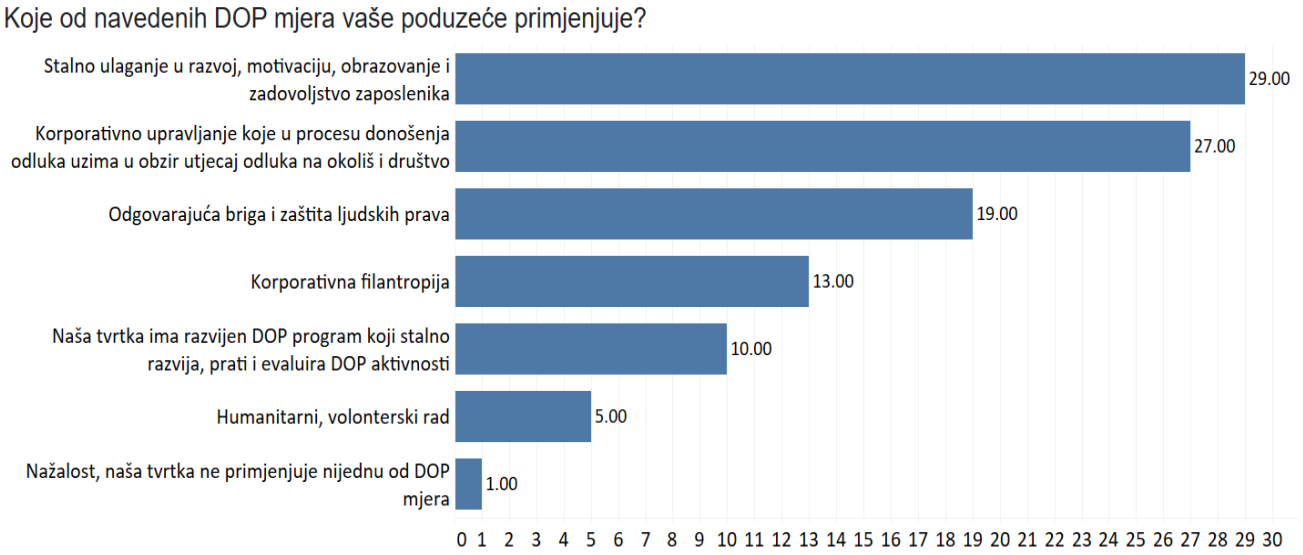

Izvor: Istraživanje autora

U tablici 1 prikazani su rezultati korelacijske analize performansi poduzeća i DOP aktivnosti.

Tablica 1. Korelacija između performansi poduzeća i DOP aktivnosti

	Odnosi s kupcima i dobavljačima	Odnosi s ostalim interesno-utjecajnim skupinama	Očuvanje okoliša	Ekološka održivost	Briga o čistoći zraka, tla i vode	Odnos prema lokalnoj zajednici	Briga za društvo, zajednicu i ljude
Tržišni udio	0.1592	0.2539	-0.1344	0.0362	0.2185	-0.0524	0.1175
p	0.3922	0.1682	0.4711	0.8468	0.2376	0.7797	0.5290
Prihod od prodaje	0.2532	0.1802	0.3541	0.1826	0.0637	0.1215	0.1004
p	0.1694	0.3320	0.0506	0.3255	0.7335	0.5151	0.5911

Izvor: Istraživanje autora

Rezultati korelacijske analize prikazani u tablici 1 ukazuju na nepostojanje statistički značajne povezanosti između različitih aspekata društveno odgovornog poslovanja i performansi poduzeća u kontekstu tržišnog udjela i prihoda od prodaje. Nadalje, analizirana je povezanost društveno odgovorna marketinške aktivnosti i percepcije poduzeća od strane različitih dionika (snaga branda, imidža, percepcija utjecaja poduzeća, privlačnost poduzeća za zaposlenike). U tablici 2 prikazani su rezultati korelacijske analize navedenih varijabli.

Tablica 2. Korelacija društveno odgovorne marketinške aktivnosti i percepcije poduzeća

	Snaga branda	Imidž i utjecaj poduzeća	Privlačnost poduzeća za zaposlenike
Društveno odgovorna marketinška aktivnost	0,6754	0,5754	0,6990
p	0,0007	0,0007	0,0043

Izvor: Istraživanje autora

Iz tablice 2 vidljivo je da su sve testirane veze statistički značajne pri razini signifikantnosti od 1% te umjerenog intenziteta. Pearsonov koeficijent korelacije pokazuje da s rastom društveno odgovorne marketinške aktivnosti raste i snaga branda. Rezultati istraživanja pokazuju i postojanje pozitivne veze između društveno odgovorne marketinške aktivnosti i imidža i utjecaja poduzeća. Dokazana je i statistički značajna pozitivna veza između društveno odgovorne marketinške aktivnosti i privlačnost poduzeća za zaposlenike. Zaposlenici poduzeća identificiraju se kroz društveno odgovorne ciljeve organizacije, što u dugom roku može dovesti do većeg zadovoljstva organizacijom.

4. ZAKLJUČAK

Društvena odgovornost sve više postaje sastavni dio organizacijskih vrijednosti i poslovnih aktivnosti poduzeća. Društveno odgovorno poslovanje podrazumijeva da poslovne aktivnosti uzimaju u obzir probleme društva te da poduzeće djeluje s osnovnim ciljem stvaranja nove vrijednosti koja će rezultirati minimalnom štetom za okoliš i maksimalnom za društvo. Dakle, poduzeća uvode i nastoje razvijati DOP na način da svoje poslovanje usmjeravaju na etičke, ekološke, obrazovne, zdravstvene i sve ostale aktivnosti.

Glavni cilj ovog rada bio je ispitati društveno odgovorno poslovanje velikih poduzeća koja posluju u Republici Hrvatskoj te analizirati povezanost društveno odgovornih aktivnosti sa performansama poduzeća, odnosno tržišnim udjelom i prihodom od prodaje. Također, u radu je analizirana povezanost društveno odgovornih marketinških aktivnosti sa snagom branda, imidžom i utjecajem poduzeća. Rezultati su pokazali da ne postoji statistički značajna veza između ispitivanih aktivnosti društveno odgovornog poslovanja i performansi poduzeća u kontekstu tržišnog udjela i prihoda od prodaje. Međutim, rezultati empirijskog istraživanja ukazali su na važnost društveno odgovornih marketinških aktivnosti. Dokazana je statistički značajna povezanost između društveno odgovornih marketinških aktivnosti i pozitivne percepcije poduzeća među interesno-utjecajnim skupinama.

Ograničenja istraživanja prvenstveno se odnose na mali uzorak i način prikupljanja podataka. Naime, veći uzorak omogućio bi bolju generalizaciju zaključaka i pouzdanije rezultate. Što se tiče metode prikupljanja podataka, upitnik podrazumijeva nedostatke kao što je pristranost odgovora. Buduća istraživanja mogla bi uključiti sekundarne podatke o ulaganjima u DOP aktivnosti te veći broj analiziranih poduzeća. Nadalje, većina empirijskih istraživanja DOP-a temelji se na uzorku velikih poduzeća, te bi bilo zanimljivo istražiti što DOP znači i kako s implementira u malim i srednjim poduzećima [Lee, 2008].

REFERENCE

[1] Agarwal, G. (2012). The Impact of Corporate Social Responsibility on Consumer Behaviour, doktorska disertacija, Universita degli studi di Milano, Milano, Italija.
[2] Aslaksen, H.M.; Hildebrandt, C.; Johnsen, H.C.G. (2021). The long-term transformation of the concept of CSR: towards a more comprehensive emphasis on sustainability. International Journal of Corporate Social Responsibility 6(11)
[3] Babić, M. (2012). Društveno odgovorno poslovanje u funkciji unapređenja imidža poduzeća. Učenje za poduzetništvo, 2(2), str. 277-285.

[4] Carroll, A. B. (2008). A history of corporate social responsibility: Concepts and practices, u: Crane, A.; Matten, D.; McWilliams, A.; Moon, J.; Siegel, D.S. (ur.) The Oxford Handbook of Corporate Social Responsibility, Oxford University Press, Oxford, UK.
[5] Carstensen, L. L. (2006). The influence of a sense of time on human development. Science, 312, str. 1913–1915.
[6] Frankental, P. (2001). Corporate social responsibility – a PR invention?. Corporate Communications: An International Journal, 6(1), str. 18-23.
[7] Glavočević, A.; Radman Peša, A. (2013). Društveno odgovorno poslovanje i CRM kao način integriranja društvene odgovornosti u marketinške aktivnosti. Oeconomica Jadertina, 3(2), str. 28-49.
[8] Grosser, K. (2009). Corporate social responsibility and gender equality: women as stakeholders and the European Union sustainability strategy. Business Ethics: A European Review, 18(3), str. 290-307.
[9] Husted, B.W.; Salazer, J.d.J. (2006). Taking Friedman seriously: Maximizing profits and social performance. Journal of Management Studies, 43(1), str. 75-91.
[10] Latapí Agudelo, M.A.; Jóhannsdóttir, L.; Davídsdóttir, B. (2019). A literature review of the history and evolution of corporate social responsibility. International Journal of Corporate Social Responsibility, 4(1)
[11] Lee, M.D. (2008). A review of the theories of corporate social responsibility: Its evolutionary path and the road ahead. International Journal of Management Reviews, 10(1), str. 53-73.
[12] Mahaček D.; Lihtar-Martinko M. (2013). Ulaganje u poslovanje putem franšize. Ekonomski vjesnik, 26(2), str. 598-609.
[13] McWilliams, A., et al. (2006). Corporate social responsibility: Strategic implications. Journal of Management Studies, 43, str. 1-18.
[14] McWilliamsS, A.; Siegel, D. (2001). Corporate social responsibility: a theory of the firm perspective. Academy of Management review, 26(1), str. 117-127.
[15] Nixon, H.; Ogunseitan, O.A.; Saphores, J.D.; Shapiro, A.A. (2007). Electronic Waste Recycling Preferences in California: The Role of Environmental Attitudes and Behaviors. Proceedings of the 2007 IEEE International Symposium on Electronics and the Environment, sre. 251-256., Orlando, FL, USA.
[16] Orlitzky, M. et al. (2011). Strategic Corporate Social Responsibility and Environmental Sustainability. Business and Society,. 50(1), str. 6-27.
[17] Osmanagić Bedenik, N.; Labaš, D. (2011). Role of corporate social responsibility (CSR) in business planning and practice of Croatian companies. Market-Tržište, 23(2), str. 143-164.
[18] Peloza, J. (2009). The Challenge of Measuring Financial Impacts From Investments in Corporate Social Performance. Journal of Management, 35(6), str. 1518–1541.
[19] Rahbek, E., Pedersen, G. (2015). The anatomy of CSR. U: Rahbek, E.; Pedersen, G. (ur.) Corporate Social Responsibility, pp. 3-36., Sage Publications Ltd, London, UK.
[20] Roberts, S. (2003). Supply chain specific? Understanding the patchy success of ethical sourcing initiatives. Journal of Business Ethics, 44(2), str. 159-170.
[21] Rondinelli, D.A.; Berry, M.A. (2000). Environmental citizenship in multinational corporations: Social responsibility and sustainable development. European Management Journal, 18(1), str. 70-84.
[22] Sacconi, L. (2019). A Rawlsian View of CSR and the Game Theory of its Implementation: the Multi-stakeholder Model of Corporate Governance. Social Responsibility and Corporate Governance, 1, 157-193.
[23] Szmigin, I., et al. (2007). Integrating ethical brands into our consumption lives. Journal of Brand Management, 14(5), str. 396-409.

[24] Wisse, B.; van Eijbergen, R.; Rietzschel, E.F. et al. (2018). Catering to the Needs of an Aging Workforce: The Role of Employee Age in the Relationship Between Corporate Social Responsibility and Employee Satisfaction. Journal of Bussines Ethics 147, str. 875–888.

Review article / Pregledni rad

STAVOVI STANOVNIŠTVA O UVOĐENJU EURA U REPUBLIKU HRVATSKU

ZRINKA LACKOVIĆ VINCEK
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
zlackovi@foi.unizg.hr

VLADIMIR KOVŠCA
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
vkovsca@foi.unizg.hr

HANA HANŽEK
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
hhanzek20@student.foi.hr

SAŽETAK

Euro je zajednička valuta zemalja članica Europske unije, uvedena s ciljem produbljivanja povezanosti između zemalja članica i boljeg iskorištavanja svih prednosti jedinstvenog tržišta, uz slobodno kretanje ljudi, kapitala, roba i usluga. Kao glavne prednosti eura ističu se uklanjanje transakcijskih troškova, dokidanje međuvalutne promjene unutar europodručja, smanjenje izloženosti valutnom riziku, olakšavanje trgovine te povećanje otpornosti gospodarstva na krize. Ukupno gledajući, euro doprinosi stabilnijim gospodarskim prilikama i rastu, većim investicijama i novim radnim mjestima. Republika Hrvatska je 01. siječnja 2023. godine uvela euro kao službenu valutu i time postala 20. zemlja članica europodručja. Stoga je cilj ovog rada ispitati stavove dijela stanovništva Republike Hrvatske o uvođenju eura kao službene valute. Proveden je online anketni upitnik, kojeg je ispunilo 185 ispitanika. Rezultati provedenog istraživanja pokazali su da se većina ispitanika još uvijek nije prilagodila na euro te osjećaju nostalgiju za hrvatskom kunom. Većina ispitanika smatra da Republika Hrvatska nije bila spremna za uvođenje eura i da nije trebala zamijeniti hrvatsku kunu eurom te da postoji više negativnih nego pozitivnih aspekata uvođenja eura u Republiku Hrvatsku.

KLJUČNE RIJEČI: euro, europodručje, Ekonomska i monetarna unija, Republika Hrvatska

PUBLIC OPINION ON THE ADOPTION OF THE EURO IN THE REPUBLIC OF CROATIA

ABSTRACT

The Euro is the common currency of European Union member countries, introduced with the aim of deepening the integration among member states and making better use of all the advantages of a single market, including the free movement of people, capital, goods, and services. The main advantages of the Euro include the elimination of transaction costs, the removal of currency exchange within the Eurozone, reduced exposure to currency risk, facilitating trade, and increasing the economy's resilience to crises. Overall, the Euro contributes to more stable economic conditions and growth, increased investments, and the creation of new jobs. On January 1, 2023, the Republic of Croatia adopted the Euro as its official currency, becoming the 20th member of the Eurozone. Therefore, the aim of this study is to examine the attitudes of part of the population of the Republic of Croatia towards the introduction of the Euro as the official currency. An online questionnaire was conducted, with 185 respondents participating. The results of the research showed that most respondents have not yet fully adjusted to the Euro and feel nostalgic for the Croatian kuna. Most respondents believe that the Republic of Croatia was not ready for the Euro's introduction and should not have replaced the Croatian kuna with the Euro, with more negative than positive aspects perceived regarding the adoption of the Euro in the Republic of Croatia.

KEYWORDS: Euro, Eurozone, Economic and Monetary Union, Republic of Croatia

1. UVOD

Europska ekonomska i monetarna unija (engl. *Economic and Monetary Union* – EMU) osnovana je 01. siječnja 1999. godine u gradu Maastrichtu u Nizozemskoj sa zajedničkom valutom euro koji se počeo koristiti od 01. siječnja 2002. godine. Glavna institucija Ekonomske i monetarne unije je Europska središnja banka, koja uz glavni cilj održavanja stabilnosti cijena, vodi zajedničku monetarnu politiku te nastoji smanjiti visoku stopu nezaposlenosti (Bilas, 2005.). Jedan od zadataka Ekonomske i monetarne unije je uvođenje zajedničke valute, odnosno eura u zemlje članice, no to je zadatak za koji je potrebno puno vremena i još nije završen, budući da neke zemlje članice EMU-a i dalje koriste svoje nacionalne valute, a ne euro. Sve zemlje članice Europske unije, osim Danske, trebaju zamijeniti svoju nacionalnu valutu eurom, međutim, one same odabiru kada će započeti taj proces, odnosno u trenutku kada zadovolje kriterije konvergencije (kriterije iz Maastrichta). U Ugovoru iz Maastrichta, koji je sklopljen 1992. godine, nisu utvrđeni konkretni rokovi za pridruživanje europodručju, već je na zemljama članicama da same razviju strategije za ispunjavanje uvjeta za uvođenje eura. Dakle, one zemlje koje žele uvesti euro kao platežnu valutu, moraju zadovoljiti sva sljedeća četiri kriterija konvergencije (Bukowski, 2006):

1) ***stabilnost cijena (inflacijski kriterij):*** prosječna stopa inflacije mjerena harmoniziranim indeksom potrošačkih cijena (engl. *Harmonized Index of Consumer Prices* – HICP) ne smije prelaziti 1,5 postotnih bodova iznad prosječne stope inflacije triju zemalja članica Europske unije s najstabilnijim cijenama (odnosno, najnižim inflacijama);
2) ***stabilnost javnih financija (fiskalni kriterij):*** zemlja kandidatkinja mora ostvariti budžetski deficit manji od 3% BDP-a i javni dug manji od 60% BDP-a;

3) ***stabilnost deviznog tečaja (tečajni kriterij):*** zemlja mora sudjelovati u tečajnom mehanizmu ERM II najmanje dvije godine bez znatnih odstupanja od središnjeg tečaja ERM-a II, a tijekom tog razdoblja središnji bilateralni tečaj njezine valute ne smije devalvirati u odnosu na euro, odnosno omogućuje fluktuaciju tečaja od 15%;
4) ***stabilnost dugoročnih kamatnih stopa (kamatni kriterij):*** dugoročne (desetogodišnje) nominalne kamatne stope na državne obveznice zemlje kandidatkinje ne smiju biti više od 2 postotna poena iznad prosjeka stopa triju zemalja članica koje su ostvarile najbolje rezultate u pogledu stabilnosti cijena (najnižu inflaciju), odnosno prosječna kamatna stopa u tri zemlje članice EU s najnižom inflacijom plus 2 postotna poena.

O tome jesu li zadovoljeni kriteriji konvergencije za uvođenje eura u zemljama kandidatkinjama za pristupanje europodručju odlučuju Europska središnja banka i Europska komisija (Matić, 2021). Nakon što se procijeni napredak u ispunjavanju kriterija konvergencije, te dvije institucije objavljuju zaključke u svojim izvješćima koja se nazivaju *Convergence Reports*, koja dodatno ratificira Vijeće za ekonomske i financijske poslove (engl. *Economic and Financial Affairs Council* – ECOFIN) u savjetovanju s Europskim parlamentom i čelnicima zemalja. Nakon pozitivnog rezultata može započeti postupak uvođenja eura. Petravić (2022) je u svom radu analizirao nominalne kriterije konvergencije za uvođenje eura u Republici Hrvatskoj te zaključio da Republika Hrvatska ispunjava sva četiri kriterija konvergencije. Njegova analiza sagledava i potvrđuje zaključak Izvješća o konvergenciji Europske središnje banke od 01. lipnja 2022. godine.

Zemlje članice EMU-a koje su uvele euro kao službenu valutu te čine europodručje su sljedeće: Austrija, Belgija, Hrvatska, Cipar, Estonija, Finska, Francuska, Njemačka, Grčka, Irska, Italija, Latvija, Litva, Luksemburg, Malta, Nizozemska, Portugal, Slovačka, Slovenija i Španjolska. Zemlje članice EMU-a koje još nisu uvele euro kao svoju službenu, jer još nisu zadovoljile kriterije konvergencije su: Bugarska, Češka, Mađarska, Poljska, Rumunjska i Švedska te su to uglavnom zemlje koje su pristupile Europskoj uniji 2004., 2007. i 2013. godine, nakon uvođenja eura 2002. godine. Danska je jedina zemlja koja je zadržala svoju valutu nakon pristupanja Europskoj uniji temeljem zakonodavnog akta. Zemlje koje nisu dio europodručja, a koriste euro kao svoju službenu valutu su: Andora, Kosovo, Crna Gora, Monako, San Marino i Vatikanski Grad.

Euro je valuta koju svakodnevno koristi više od 340 milijuna ljudi, što ga čini drugom najčešće korištenom valutom na svjetskoj razini. Novčanice eura jednake su u svim zemljama koje čini europodručje te europski novac dolazi u sedam apoena novčanica u vrijednostima od 5, 10, 20, 50, 100, 200 i 500 eura. Kovanice eura djelomično se razlikuju u zemljama europodručja, odnosno kovanice u svim zemljama imaju isto lice, a različito naličje. Europski novac dolazi u osam apoena kovanica u vrijednostima 1 i 2 eura te 1, 2, 5, 10, 20 i 50 centi.

Budući da je Republika Hrvatska 01. siječnja 2023. godine uvela euro kao službenu valutu i time postala 20. zemlja članica europodručja, cilj ovog rada je ispitati stavove dijela stanovništva Republike Hrvatske o uvođenju eura kao službene valute, temeljem *online* anketnog upitnika. Pregledom postojeće literature nije pronađeno ni jedno empirijsko istraživanje koje istražuje zadovoljstvo stanovništva uvođenjem eura kao službene valute u Republiku Hrvatsku; stoga ovaj rad popunjava važnu prazninu u tome segmentu. S ciljem utvrđivanja stavova stanovništva o uvođenju eura kao službene valute u Republiku Hrvatsku, u ovom istraživanju nastojalo se pronaći odgovor na sljedeća istraživačka pitanja: (1) postoji li kod stanovnika Republike Hrvatske izražen stav o uvođenju eura kao službene valute?, (2) Je

li uvođenje eura kao službene valute pozitivno utjecalo na stavove stanovnika Republike Hrvatske?, (3) Osjećaju li stanovnici Republike Hrvatske nostalgiju za hrvatskom kunom?

Struktura rada je sljedeća. Nakon uvodnog razmatranja, u drugom poglavlju daje se teorijski okvir istraživanja. U trećem poglavlju objašnjava se metodologija provedenog istraživanja, dok se u četvrtom poglavlju iznose ključni rezultati istraživanja. Konačno, u petom poglavlju sumiraju se najvažniji zaključci do kojih se radom došlo te se navode ograničenja i preporuke za buduća istraživanja.

2. TEORIJSKI OKVIR ISTRAŽIVANJA

Republika Hrvatska krenula je s pripremama za uvođenje eura 2017. godine kada je Hrvatska narodna banka analizirala ekonomske koristi i troškove uvođenja eura u Republiku Hrvatsku, te zaključila da su koristi uvođenja eura veće od troškova. Prije samog uvođenja eura, u Republici Hrvatskoj je već bio prisutan proces eurizacije, odnosno euro je imao jednu ili više funkcija hrvatske kune te je na taj način počeo istiskivati kunu iz opticaja (Tica i sur., 2016). Primjerice, prije same obveze dvojnog iskazivanja cijena, neki poduzetnici, primjerice oni koje su se bavili prodajom nekretnina, automobila i slično, svoje cijene su izražavali i u kunama i u eurima.

Prema Smjernicama za prilagodbu gospodarstva u procesu zamjene hrvatske kune eurom (Ministarstvo gospodarstva RH, 2022), postojala su tri ključna razdoblja: pripremno razdoblje, razdoblje dvojnog optjecaja te razdoblje nakon završetka dvojnog optjecaja. Pripremno razdoblje započelo je šest mjeseci prije službenog uvođenja eura. U samom početku pripremnog razdoblja, Vlada Republike Hrvatske morala je definirati fiksni tečaj konverzije, točan datum kada se uvodi euro, datume koji su vezani uz početak i kraj dvojnog optjecaja kune i eura te datume koji govore o početku i kraju dvojnog iskazivanja cijena. Najznačajnije radnje koje se moraju obaviti u pripremnom razdoblju su priprema gospodarstva, institucija i svih ostalih subjekata za uvođenje eura, prilagodba računovodstvenih sustava poslovnih subjekata, informiranje i educiranje javnosti o euru, opskrba euro novčanicama i kovanicama i ostale radnje (Hrvatska narodna banka, 2018). Nakon pripremnog razdoblja slijedi razdoblje dvojnog optjecaja, odnosno razdoblje u kojem se mogu koristiti i kune i euri. Svrha ovog razdoblja je dati građanima mogućnost da zamijene prestale kune eurom. Razdoblje dvojnog optjecaja traje dva tjedna od datuma uvođenja eura, odnosno u Republici Hrvatskoj je trajao od 01. siječnja 2023. godine do 14. siječnja 2023. godine. Posljednje razdoblje, odnosno razdoblje nakon završetka dvojnog optjecaja započinje nakon što završi prethodno razdoblje, odnosno razdoblje dvojnog optjecaja i u tom razdoblju euro postaje službena valuta u Republici Hrvatskoj i kuna više nije u optjecaju. U razdoblju od šest mjeseci od uvođenja eura, građani mogu jedino kod banaka zamijeniti kune za euro, uz proviziju banke, a nakon proteka 12 mjeseci od uvođenja eura, zamjena kune za euro biti će moguća samo kod Hrvatske narodne banke, i to kovanice u roku od tri godine od uvođenja eura, a novčanice uz neograničen rok.

Pregledom postojeće literature, uočen je nedostatak istraživanja o zadovoljstvu stanovništva uvođenjem eura kao službene valute. Istraživanja su uglavnom bila usmjerena na mjerenje koristi i učinaka pristupanja neke zemlje članice Europske unije Ekonomskoj i monetarnoj uniji i ispitivanjem zadovoljstva samog života u Europskoj uniji. Tako su, primjerice, neka istraživanja pokazala da EMU ima slabije učinke na trgovinu od ostalih unija. Glick i Rose (2002) u svom radu su upozorili da se rezultati do kojih su došli, zasnovani na uzorku velikog broja zemalja uključenih u razne monetarne unije, ne mogu direktno primijeniti za ocjenu

budućih učinaka ulaska u EMU, jer se njihov istraživački uzorak temelji uglavnom na manjim i siromašnijim zemljama. Eicher i Henn (2011) dublje su istražili razlike između pojedinih valutnih područja i zaključili da je intenziviranje trgovine u slučaju eura slabije nego li kod ostalih monetarnih unija. Glick (2017) dokazuje statistički značajan i pozitivan učinak uvođenja eura na trgovinu, koji je zamjetno slabiji od učinka pristupanja Europskoj uniji.

Bukovšak i suradnice (2018) provele su istraživanje o koristima uvođenja eura za međunarodnu razmjenu i inozemna izravna ulaganja u Republici Hrvatskoj te došle do zaključka da bi učinak uvođenja eura na hrvatsku međunarodnu razmjenu i izravna ulaganja mogao biti pozitivan. Navode da bi uvođenje eura u Republici Hrvatskoj moglo povećati robnu razmjenu, ali relativno slabije nego ulazak u Europsku uniju. U pogledu utjecaja uvođenja eura na inozemna izravna ulaganja u Republiku Hrvatsku, istaknule su da bi zajednička valuta mogla ohrabriti ulagače smanjivanjem tečajnih neizvjesnosti i ostalih neformalnih prepreka ulaganjima te poboljšati poslovnu klimu, a time potaknuti inozemna izravna ulaganja.

S obzirom da pregledom postojeće literature nije pronađeno ni jedno empirijsko istraživanje koje istražuje zadovoljstvo stanovništva uvođenjem eura kao službene valute u Republiku Hrvatsku, ovaj rad popunjava važnu prazninu u tome segmentu.

3. METODOLOGIJA ISTRAŽIVANJA

U prvom dijelu rada korištena je metoda kompilacije kako bi se detaljno prikazao teorijski okvir, odnosno objedinila različita razmišljanja i razlozi pojave, ali i navele činjenice o uvođenju eura u zemlje članice Europske unije. Nadalje, u radu se dijelom u samom istraživanju koristi deduktivna metoda, ali u obliku metode generalizacije. Metoda generalizacije koristi se prilikom opažanja pojedinačnih i utvrđivanja općenitih stavova o uvođenju eura kao službene valute u Republiku Hrvatsku. Konačno, u istraživanju se koristi i metoda indukcije pomoću koje se, na temelju analize svih pojedinih dijelova, dolazi do konačnog zaključka o stavovima ispitanika o uvođenju eura u Republiku Hrvatsku.

Nakon uvođenja eura u Republiku Hrvatsku te aktivnog korištenja eura u trajanju od šest mjeseci, provedena je *online* anketa nad dijelom stanovništva Republike Hrvatske vezano uz njihove stavove o uvođenju eura kao službene valute u Republiku Hrvatsku. Kreiran je anonimni *online* anketni upitnik te su ispitanici ispunjavanjem *online* anketnog upitnika dali informirani pristanak za sudjelovanje u ovom istraživanju. Anketni upitnik kreiran je i distribuiran putem digitalne platforme Google Forms te je podijeljen na društvenim mrežama (Facebook, Instagram, LinkedIn) i poslan na *e-mail* adrese, stoga se radilo o namjernom slučajnom prigodnom uzorku, prikupljenom metodom lavine. Odgovori su prikupljani u periodu od 02. svibnja 2023. godine do 02. lipnja 2023. godine.

Anketni upitnik je sadržavao ukupno 27 pitanja, podijeljenih u tri skupine: (1) demografski podaci o ispitanicima, (2) opće znanje ispitanika o euru te (3) osobno iskustvo ispitanika o uvođenju i korištenju eura u Republici Hrvatskoj. Od velikog broja korisnika društvenih mreža koji su bili pozvani na sudjelovanje u istraživačkom projektu, anketnom upitniku je pristupilo te u konačnici u potpunosti ispunilo ukupno 185 ispitanika te je na njihovim odgovorima provedena statistička analiza prikazana u nastavku rada. Demografske karakteristike ispitanih pokazuju kako je veći dio ispitanih bio ženskog spola.

4. REZULTATI ISTRAŽIVANJA

Kako je ranije navedeno, istraživanjem su ispitani stavovi dijela stanovništva o uvođenju eura kao službene valute u Republiku Hrvatsku, a najznačajniji rezultati uspoređeni su u nastavku rada. Anketnim upitnikom analizirali su se najprije demografski podaci ispitanika te su rezultati prikazani u nastavku.

Prema spolu, u anketi je sudjelovalo 127 žena (69%) i 57 muškaraca (31%). S obzirom na dob ispitanika, a što je prikazano na prikazu 1., u anketi je najviše sudjelovalo ispitanika u dobnoj skupini između 18 i 25 godina (141, 76,6%), zatim 19 ispitanika u dobi od 26 do 35 godina (10,3%), 12 ispitanika u dobi od 36 do 45 godina (6,5%), 8 ispitanika u dobnoj skupini između 46 i 55 godina (4,3%) te 3 ispitanika u dobnoj skupini između 56 i 65 godina (1,6%). Samo jedan ispitanik nalazi se u dobnoj skupini iznad 65 godina (0,5%).

Prikaz 1. Dob ispitanika

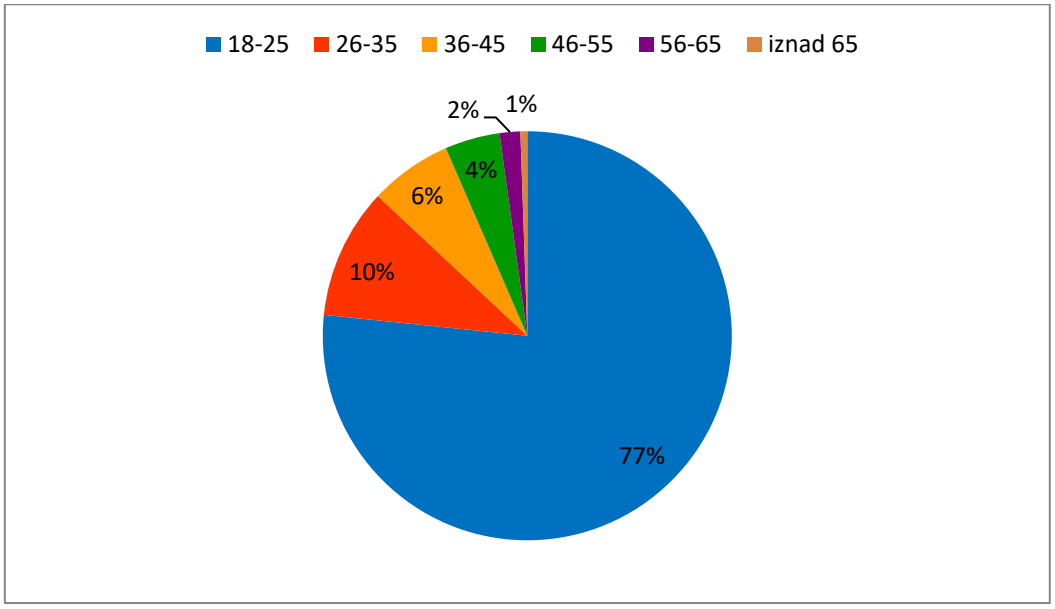

Vezano uz razinu obrazovanja (prikaz 2.), u anketi su najviše sudjelovali ispitanici s fakultetskim obrazovanjem (48,9%), nakon kojih slijede oni sa završenom srednjom stručnom spremom (42,9%) te magisterijem (4,9%). Najmanji udio ispitanika (3,3%) ima završen doktorat znanosti.

Prikaz 2. Razina obrazovanja

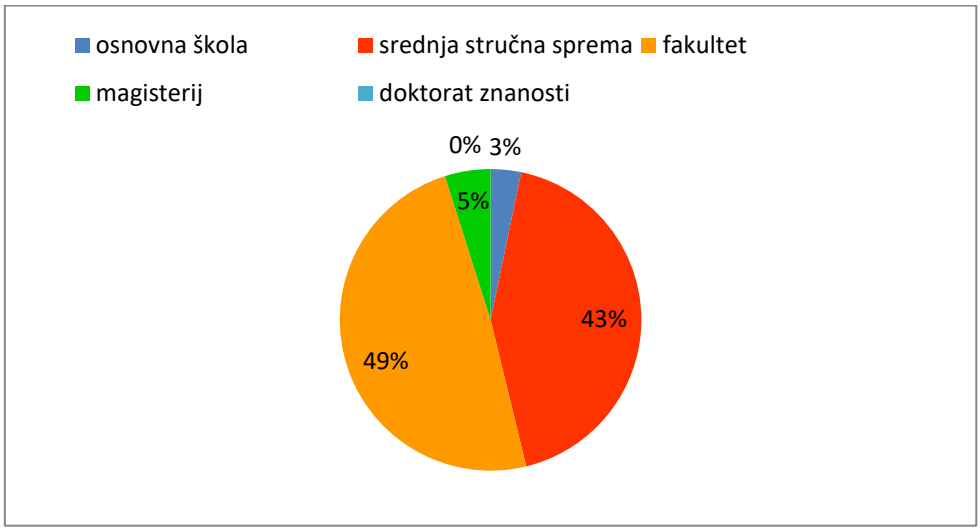

S obzirom na trenutni radni status ispitanika (prikaz 3.), najviše ih studira (70,1%), zatim slijede ispitanici koji su zaposleni na neodređeno (17,4%) te ispitanici zaposleni na određeno (6,5%). Nezaposlenih je 3,8% ispitanika, dok ih se 2,2% nalazi u mirovini.

Prikaz 3. Radni status

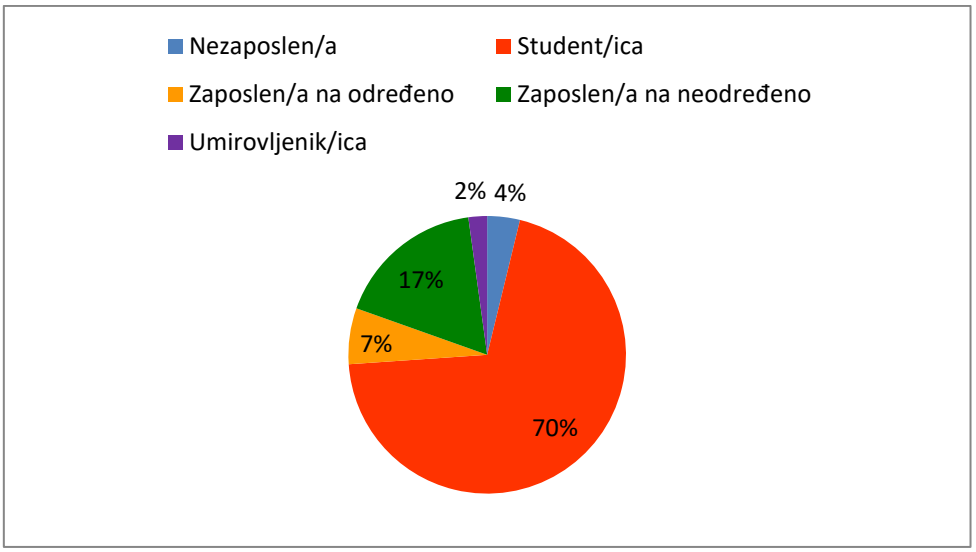

Nakon demografskih podataka, analizirano je opće znanje ispitanika o Europskoj uniji, poznavanju eura te institucija Europske unije, a rezultati su prikazani u nastavku.

Na pitanje o datumu pristupa Republike Hrvatske Europskoj uniji, 85,4% ispitanika odgovorilo je točno da je Republika Hrvatska pristupila Europskoj uniji dana 01. srpnja 2013. godine (prikaz 4.).

Prikaz 4. Datum pristupanja Republike Hrvatske Europskoj uniji

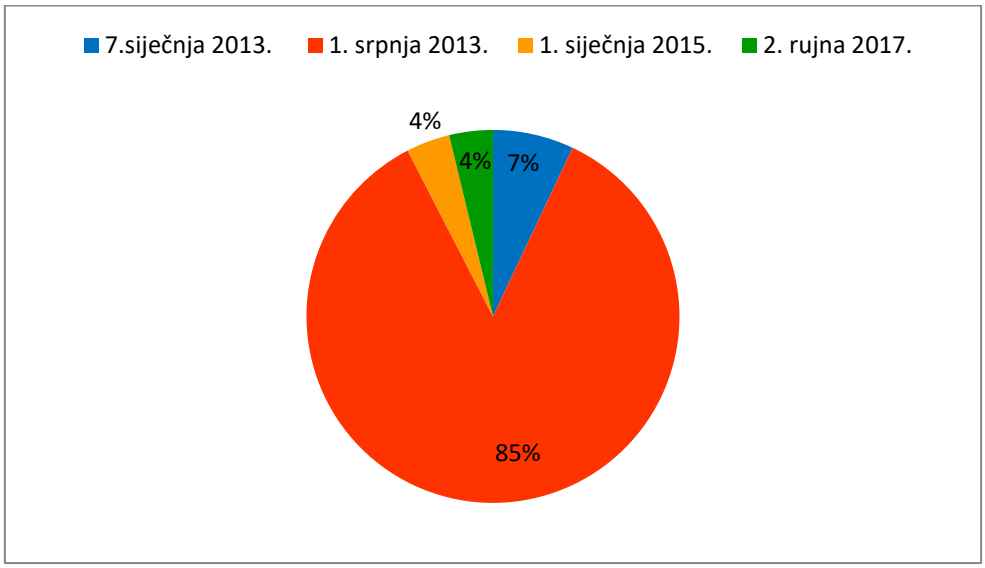

Na pitanje o organizaciji čiji je glavni cilj uvođenje eura u zemlje članice Europske unije (prikaz 5.), više od polovice ispitanika, točnije 51,9% odgovorilo je netočno, odnosno da je to Europska središnja banka. Svega 32,4% ispitanika odgovorilo je točno da je to Ekonomska i monetarna unija, dok je 11,9% ispitanika smatralo da je to Euroskupina.

Prikaz 5. Odgovorna organizacija za uvođenje eura u zemlje članice

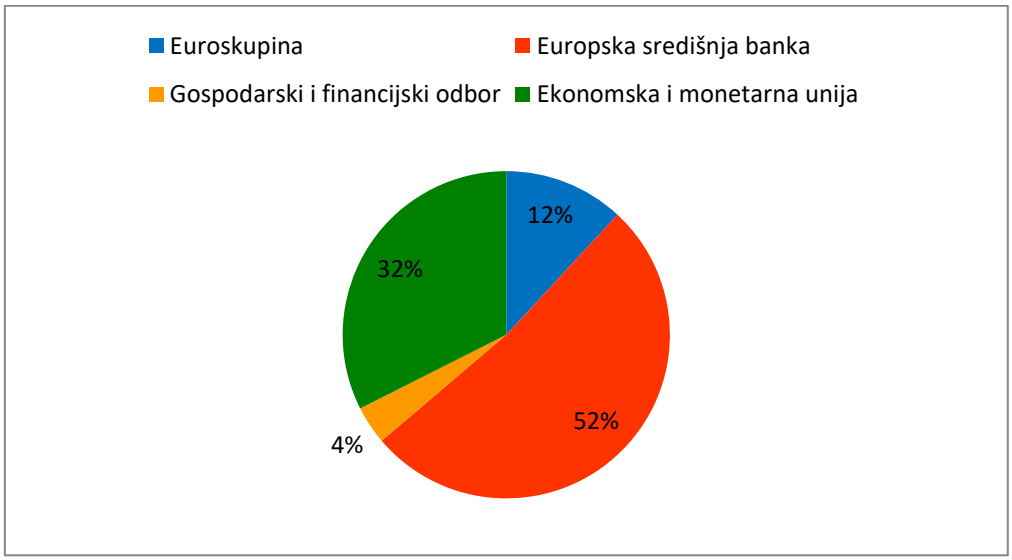

Svega 37,5% ispitanika odgovorilo je točno da je euro službena valuta u 20 zemalja članica Europske unije (prikaz 6.). Od ukupnog broja ispitanika, 32,1% njih smatra da je euro službena valuta u 24 zemlje članice, 25,5% ispitanika smatra da je to u 18 zemalja članica, dok 4,9% ispitanika smatra da je euro službena valuta u 27 od 27 zemalja članica Europske unije.

Prikaz 6. Broj zemalja za koje ispitanici smatraju da imaju euro kao službenu valutu

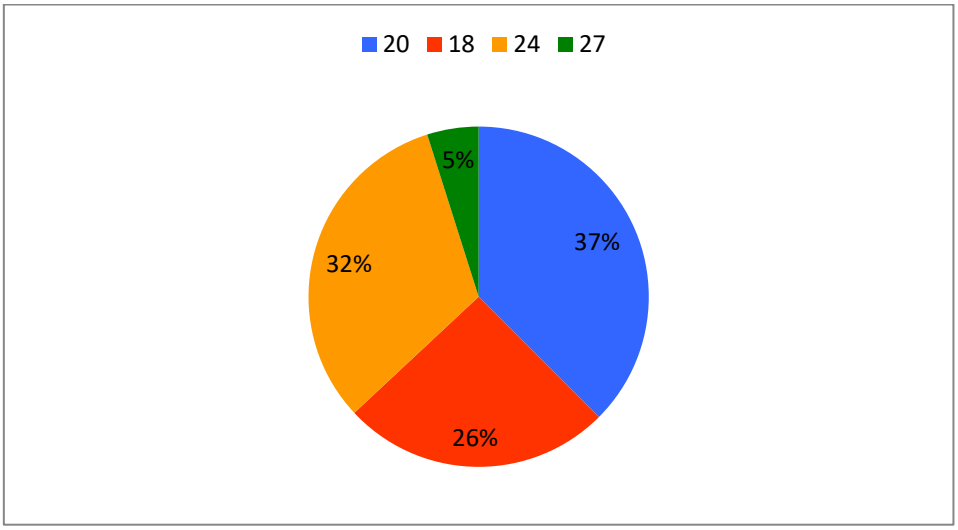

Na pitanje o tome jesu li novčanice eura iste u svim zemljama u kojima je euro službena valuta, 56,5% ispitanika odgovorilo je točno, odnosno da su novčanice eura iste u svim zemljama europodručja. Njih 40,2% odgovorilo je da se novčanice eura razlikuju u zemljama članicama EU, dok je 3,3% ispitanika ne zna odgovor na ovo pitanje.

Od ukupnog broja ispitanika, 91,3% ispitanika zna da se kovanice eura djelomično razlikuju u zemljama u kojima je euro službena valuta. Nadalje, 5,4% ispitanika smatra da se kovanice eura ne razlikuju u zemljama članicama EU, dok je 3,3% ispitanika ne zna odgovor na ovo pitanje.

Na pitanje do kojeg datuma traje obveza dvojnog iskazivanja cijena u RH (prikaz 7.), 73,5% ispitanika odgovorilo je točno, da je to do 31. prosinca 2023. godine. Od ukupnog broja ispitanika, 21,1% ispitanika smatra da je to do 01. siječnja 2024. godine, 3,2% ispitanika da to traje do 31. prosinca 2024. godine te 2,2% ispitanika smatra da obveza dvojnog iskazivanja cijena traje do 01. studenog 2023. godine.

Prikaz 7. Trajanje obveze dvojnog iskazivanja cijena u Republici Hrvatskoj

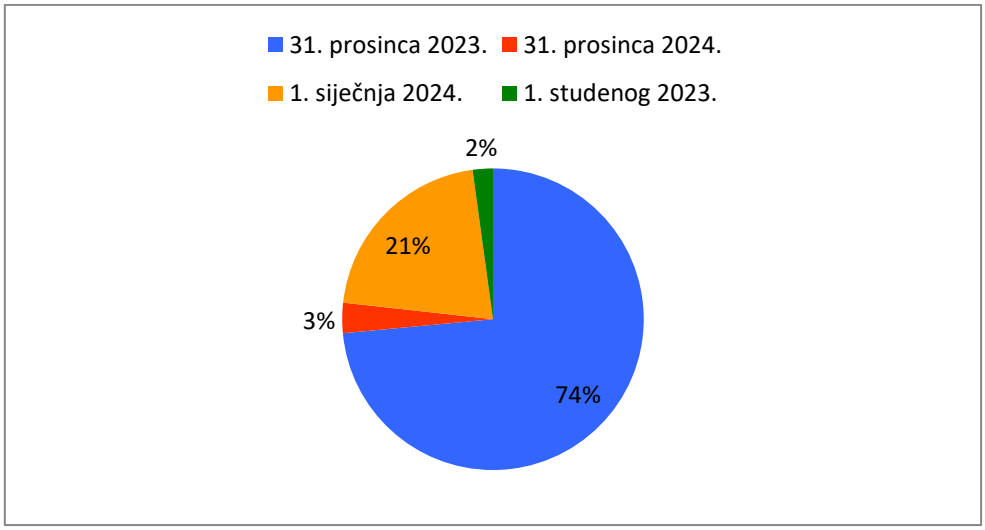

Od ukupnog broja ispitanika, 50% ispitanika smatra da se obveza dvojnog iskazivanja cijena u Republici Hrvatskoj ne bi trebala produljiti, dok 40,8% ispitanika smatra da bi se trebala produljiti (prikaz 8.). Nadalje, 9,2% ispitanika izjasnilo se da ne zna da li bi se trebala produljiti obveza dvojnog iskazivanja cijena u Republici Hrvatskoj.

Prikaz 8. Produljenje obveze dvojnog iskazivanja cijena u Republici Hrvatskoj

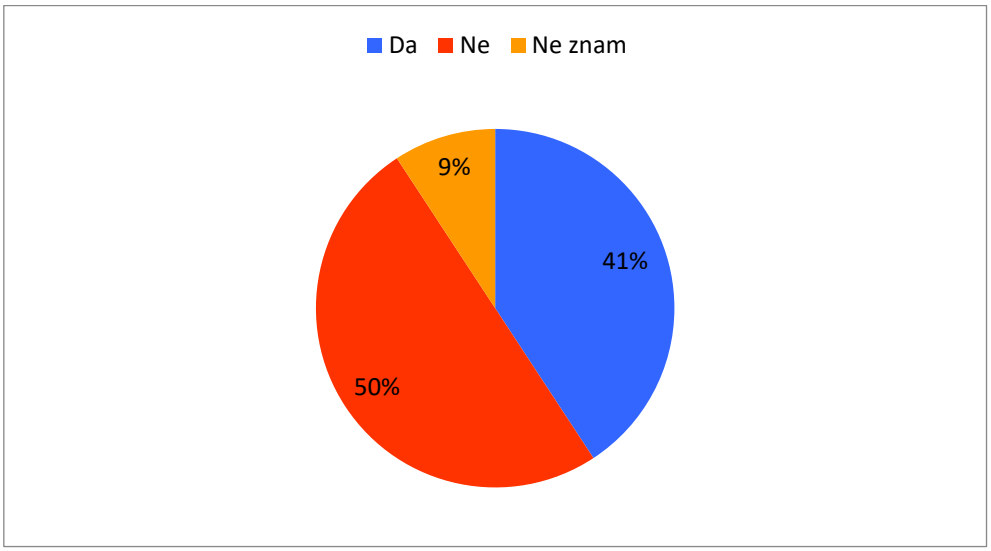

Od ukupnog broja ispitanika, 67,6% ispitanika ne obraća pažnju prilikom kupovine o tome je li neki poslovni objekt pristupio Etičkom kodeksu, dok svega 32,4% ispitanika preferira kupnju kod onih poslovnih subjekata koji su pristupili Etičkom kodeksu.

Konačno, istraživanje je obuhvatilo i osobna iskustva i stavove dijela stanovništva o uvođenju eura kao službene valute u Republiku Hrvatsku, a rezultati tog dijela istraživanja prikazani su u nastavku. Prije uvođenja eura kao službene valute u Republiku Hrvatsku, 84% ispitanika koristilo je novčanice i kovanice eura, dok 15,8% ispitanika nije koristilo euro novčanice i kovanice sve do uvođenja eura. Na pitanje smatraju li ispitanici da je uvođenje eura pozitivno utjecalo na gospodarsko stanje u zemljama koje su uvele euro prije Republike Hrvatske, 41,8% ispitanika smatra da nije pozitivno utjecalo, 31,5% ispitanika da je pozitivno utjecalo, dok 26,6% ispitanika ne zna odgovor na ovo pitanje.

Uvođenje eura kao službene valute u Republiku Hrvatsku podržavalo je 38,6% ispitanika, protiv uvođenja eura bilo je 40,8% ispitanika, dok ih je 20,7% bilo suzdržanih. Na pitanje o spremnosti Republike Hrvatske za uvođenje eura kao službene valute, više od polovice ispitanika, točnije 64,7% ispitanika smatra da Republika Hrvatska nije bila spremna za uvođenje eura, dok svega 21,2% ispitanika smatra da je Republika Hrvatska bila spremna za uvođenje eura. Više od polovice ispitanika (51,6%) smatra da Republika Hrvatska nije trebala zamijeniti hrvatsku kunu eurom, s obzirom na stabilnost hrvatske kune, dok ih 23,4% smatra da je Republika Hrvatska trebala zamijeniti kunu eurom.

Kao glavnu prednost uvođenja eura u Republiku Hrvatsku (prikaz 9.), 57,3% ispitanika smatra da je to poticaj međunarodnoj razmjeni i jačanju konkurentnosti. Nadalje, 51,4% ispitanika kao glavnu prednost smatra mogućnost pristupa europskim mehanizmima financijske pomoći. Kao glavnu prednost, 43,2% ispitanika ističe uklanjanje valutnog rizika, a 32,4% ispitanika manje transakcijske troškove. Nadalje, 22,7% ispitanika smatra da je glavna prednost uvođenja eura

kao službene valute smanjenje mogućnosti izbijanja bankovne i valutne krize, a 21,6% ispitanika smatra da je glavna prednost smanjenje naknada plaćanja. Svega 15,7% ispitanika kao glavnu prednosti vidi manji trošak zaduživanja za domaće subjekte, a svega 0,5% ispitanika kao glavnu prednost navelo je olakšan proces kupovine, posebice u turizmu.

Prikaz 9. Glavne prednosti uvođenja eura kao službene valute u Republici Hrvatskoj

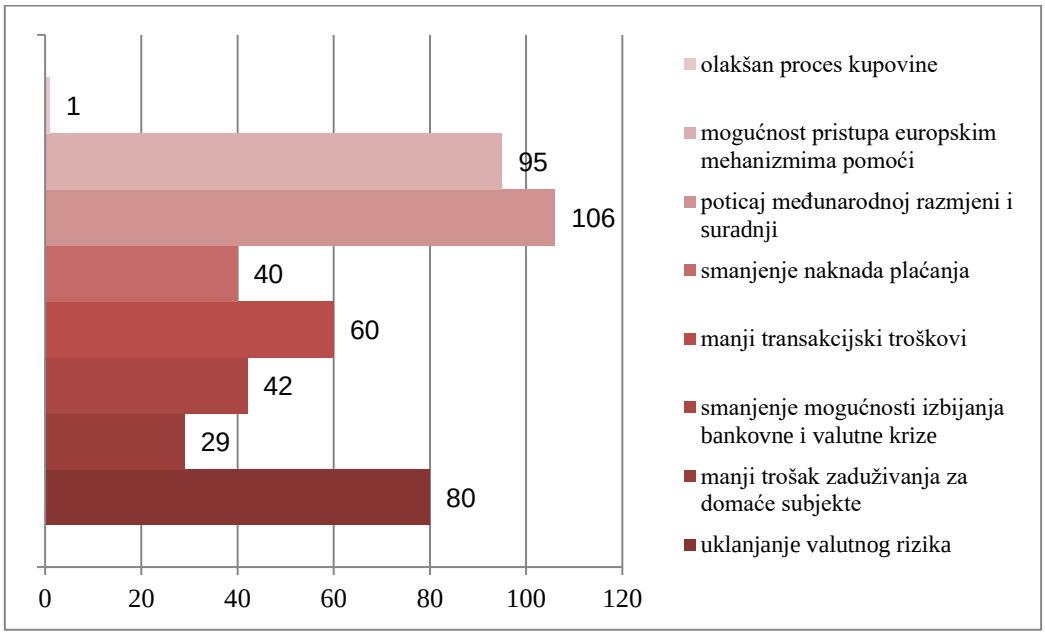

Kao glavni nedostatak uvođenja eura kao službene valute u Republiku Hrvatsku (prikaz 10.), većina ispitanika (82,7%) smatra da je to porast razine cijena. Nadalje, 50,8% ispitanika smatra da je glavni nedostatak uvođenja eura gubitak samostalne monetarne politike, a 33% ispitanika navelo je nedostatak slobode građana u izboru valute.

Prikaz 10. Glavni nedostatci uvođenja eura kao službene valute u Republici Hrvatskoj

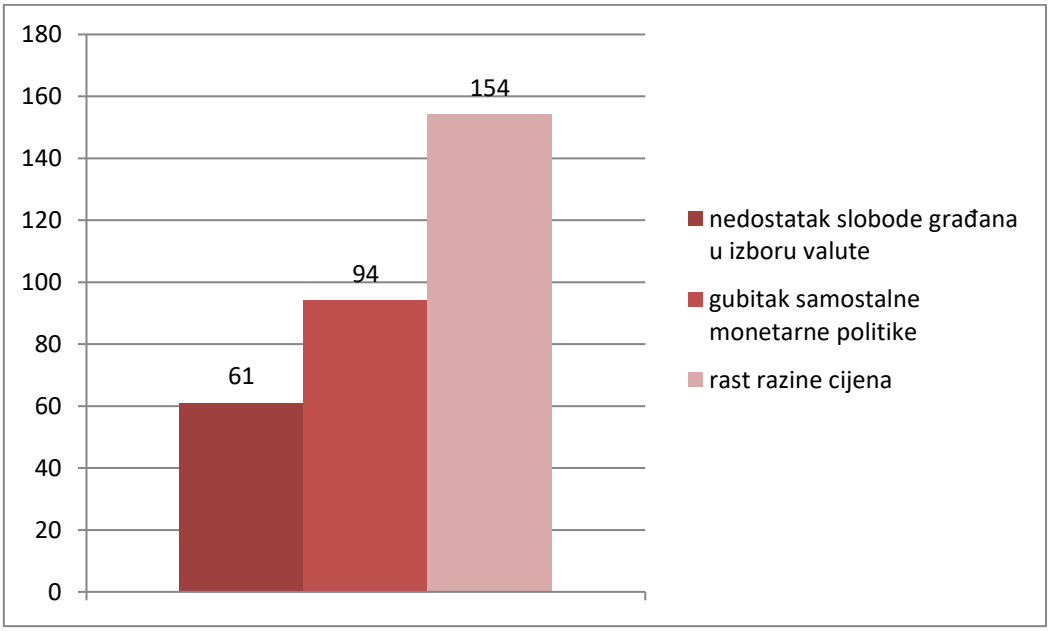

Od ukupnog broja ispitanika, 83,2% ispitanika smatra da je konverzija kune u euro doprinijela inflaciji, odnosno općem porastu cijena dobara i usluga, dok svega 16,8% ispitanika smatra da inflacija nije bila poduprta uvođenjem eura kao službene valute. Na pitanje jesu li svi poslovni subjekti poštovali fiksni tečaj konverzije kuna u euro ili su neki iskoristili priliku za neopravdano podizanje cijena, većina ispitanika (90,2%) smatra da su neki poslovni subjekti iskoristili uvođenje eura za neopravdano podizanje cijena, dok ih samo 9,8% smatra da je poštovan fiksni tečaj konverzije kuna u euro od svih poslovnih subjekata.

Više od polovice ispitanika, točnije 53,8% smatra da uvođenje eura u Republiku Hrvatsku nije imalo pozitivan utjecaj na njih osobno, 28,8% ispitanika smatra da je uvođenje eura imalo pozitivan utjecaj na njih, dok 17,4% ispitanika ne zna odgovor na ovo pitanje.

Od ukupnog broja ispitanika, 37% ispitanika je prije uvođenja eura u Republiku Hrvatsku već štedjelo u eurima, dok ih 63% nije štedjelo. Prije uvođenja eura kao službene valute u Republiku Hrvatsku, 58,7% ispitanika je već obavljalo novčane transakcije u euro novčanicama i kovanicama, dok 41,3% ispitanika nije. Nakon uvođenja eura kao službene valute u Republiku Hrvatsku, 73,4% ispitanika koristi više kartično plaćanje, a 26,6% ne koristi više kartično plaćanje u odnosu na ranije.

Na pitanje jesu li se ispitanici prilagodili na euro ili i dalje većinu cijena koje su izražene u eurima preračunavaju u kune, njih 73,5% smatra da se nisu prilagodili na euro, dok ih svega 26,5% smatra da se jesu prilagodili na euro. Od ukupnog broja ispitanika, 60,9% ispitanika osjeća nostalgiju za hrvatskom kunom i nije se priviknulo na euro kao službenu valutu, dok se na euro priviknulo 39,1% ispitanika.

5. DISKUSIJA I ZAKLJUČAK

Republika Hrvatska zadovoljila je gotovo sve kriterije konvergencije koje određuje Ekonomska i monetarna unija te je uvela euro kao svoju službenu valutu. Kriterij konvergencije odnose se na stabilnost cijena, dugoročne kamatne stope, stabilnost financija i stabilnost tečaja te je Republika Hrvatska zadovoljila sve kriterije, osim jednog kriterija koji nije formalno ispunjen, a to je stabilnost tečaja.

Nakon uvođenja eura u Republiku Hrvatsku, mnogo ekonomskih i financijski aspekata se promijenilo, poput činjenice da je Republika Hrvatska postala članicom Europske središnje banke čija je glavna zadaća reguliranje količine novca u optjecaju, odnosno ako je prisutna visoka stopa inflacije, da poveća kamatne stope po kojoj se kojoj se poslovne banke mogu zaduživati kod Europske središnje banke te se ujedno time i povećava kamatna stopa po kojoj se građani zadužuju kod poslovnih banaka što dovodi do smanjenja količine novca u optjecaju. Nadalje, Hrvatska narodna banka je s uvođenjem eura postala članica Eurosustava.

Cilj ovog istraživanja bio je utvrditi stupanj zadovoljstva hrvatskog stanovništva uvođenjem eura kao službene valute u Republiku Hrvatsku i u tu svrhu kreiran je *online* anketni upitnik. Anketni upitnik sastojao se od 27 pitanja, podijeljenih u tri dijela, na koje je u konačnici odgovorilo 185 ispitanika. Analizom demografskih podataka ispitanika uočeno je da su ispitanici bili uglavnom ženskog spola (69%), u dobi između 18 i 25 godina (76,6%) i u statusu studenta (70,1%).

Analiza općeg znanja ispitanika o Europskoj uniji te institucijama Europske unije pokazala je da ispitanici uglavnom znaju da je Republika Hrvatska pristupila Europskoj uniji dana 01. srpnja 2013. godine (85,4%). Međutim, samo trećina ispitanika (32,4%) zna da je Ekonomska i monetarna unija odgovorna organizacija za uvođenje eura u zemlje članice Europske unije, kao i da je euro službena valuta u 20 zemalja članica Europske unije (37,5%). Vezano uz poznavanje euro novčanica i kovanica, istraživanje je pokazalo da nešto više od polovice ispitanika (56,5%) zna da su novčanice eura iste u svim zemljama europodručja, a gotovo svi (91,3%) da se kovanice eura djelomično razlikuju u zemljama u kojima je euro službena valuta. Više od dvije trećine ispitanika (73,5%) upoznato je da obveza dvojnog iskazivanja cijena u Republici Hrvatskoj traje do 31. prosinca 2023. godine i polovica ih smatra da se obveza dvojnog iskazivanja cijena u Republici Hrvatskoj ne bi trebala produljiti. Većina ispitanika (67,6%) ne obraća pažnju prilikom kupovine o tome je li neki poslovni objekt pristupio Etičkom kodeksu.

Konačno, analiza osobnog iskustva i stavova dijela stanovništva o uvođenju eura kao službene valute u Republiku Hrvatsku pokazala je da je uvođenje eura kao službene valute u Republiku Hrvatsku podržalo manje od polovice ispitanika (38,6%), premda ih je veliki udio (84%) koristio novčanice i kovanice eura prije uvođenja u Republiku Hrvatsku. Također, manje od trećine ispitanika (31,5%) smatra da je uvođenje eura pozitivno utjecalo na gospodarsko stanje u zemljama koje su uvele euro prije Republike Hrvatske. Više od polovice ispitanika navelo je da su glavne prednosti uvođenja eura kao službene valute u Republici Hrvatskoj poticaj međunarodnoj razmjeni i jačanju konkurentnosti (57,3%) i mogućnost pristupa europskim mehanizmima financijske pomoći (51,4%). S druge strane, kao glavni nedostatak uvođenja eura kao službene valute u Republiku Hrvatsku većina ispitanika navela je porast razine cijena (82,7%) i gubitak samostalne monetarne politike (50,8%). Nadalje, više od dvije trećine ispitanika (83,2%) smatra da je konverzija kune u euro doprinijela inflaciji, odnosno općem porastu cijena dobara i usluga te da su neki poslovni subjekti iskoristili uvođenje eura za neopravdano podizanje cijena i nisu poštovali fiksni tečaj konverzije kuna u euro (90,2%).

Općeniti zaključak koji proizlazi iz provedenog istraživanja jest da se većina ispitanika nije prilagodila na euro (73,5%). Također, veliki dio ispitanika (64,7%) smatra da Republika Hrvatska nije bila spremna za uvođenje eura, da uopće nije ni trebala zamijeniti kunu eurom (51,6%) te da postoji više negativnih nego pozitivnih aspekata uvođenja eura u Republiku Hrvatsku.

Kroz rezime rezultata istraživanja, moguće je ponuditi sljedeće odgovore na istraživačka pitanja: (1) stanovnici Republike Hrvatske imaju jasno izražen stav o uvođenju eura kao službene valute i (2) moguće je zaključiti da je uvođenje eura kao službene valute negativno utjecalo na stavove stanovništva Republike Hrvatske. (3) Posljedično, stanovnici Republike Hrvatske u velikoj mjeri osjećaju nostalgiju za hrvatskom kunom.

Premda provedeno istraživanje daje jasne rezultate, istovremeno ima brojna ograničenja koja je u daljnjem istraživačkom radu moguće ukloniti. Istraživanje je provedeno na uzorku od 158 ispitanika, uglavnom u dobi između 18 i 25 godina i u statusu studenta. Stoga se u budućim istraživanjima preporuča proširiti uzorak na starije dobne skupine te ispitanike u radnom odnosu, jednako kao i umirovljenike. Upravo stavovi različitih skupina ispitanika mogu dati jasniju sliku o percepciji i zadovoljstvu Hrvata uvođenjem eura kao službene valute. Osim većeg uzorka, ovo je istraživanje moguće proširiti i kroz detaljnije ispitivanje stavova i ekonomskog položaja stanovništva Republike Hrvatske nakon uvođenja eura kao službene valute. Konačno, s obzirom da je Vlada Republike Hrvatske u godinama prije uvođenja eura

isticala veće koristi uvođenja eura kao službene valute od troškova, u budućim istraživanjima valjalo bi istražiti utjecaj uvođenja eura na pojedince, poduzeća, ali i cjelokupno nacionalno gospodarstvo.

REFERENCE

[1] Bilas, V. (2005). Teorija optimalnog valutnog područja; euro i Europska monetarna unija. *Zbornik ekonomskog fakulteta u Zagrebu*, 3 (1), str. 39-53.

[2] Bukovšak, M., Ćudina, A., i Pavić, N. (2018). Utjecaj uvođenja eura u Hrvatskoj na međunarodnu razmjenu i inozemna izravna ulaganja. *Privredna kretanja i ekonomska politika*, 27 (1 (142)), str. 95-128. doi: 10.15179/pkiep.27.1.3.

[3] Bukowski, S. (2006). The Maastricht convergence criteria and economic growth in the EMU. *Quaderni del Dipartimento di Economia, Finanza e Statistica*, 24, 1-19.

[4] Eicher, T. S., i Henn, C. (2011). One money, one market: A revised benchmark. *Review of International Economics*, 19 (3), str. 419-435. doi: 10.1111/j.1467-9396.2011.00956.x.

[5] Glick, R. (2017). Currency unions and regional trade agreements: EMU and EU effects on trade. *Comparative Economic Studies*, 59 (2), str. 194-209. doi: 10.1057/s41294-017-0020-x.

[6] Glick, R., i Rose, A. (2002). Does a Currency Union Affect Trade? The Time Series Evidence. *European Economic Review*, 46 (6), str. 1125-1151. doi: 10.1016/S0014-2921(01)00202-1.

[7] Hrvatska narodna banka (2018) Smjernice za uvođenje eura kao službene valute u Republici Hrvatskoj. Dostupno na: https://www.mingo.hr/public/documents/Eurostrategija%20-%20FINAL.pdf

[8] Matić, B. (2021). Ekonomska i monetarna unija–rješenje za sve države Europske unije. *Numizmatičke Vijesti*, 74 (1), str. 119-133.

[9] Ministarstvo gospodarstva RH (2022) Smjernice za prilagodbu gospodarstva u procesu zamjene hrvatske kune eurom [online]. Dostupno na: https://mingor.gov.hr/UserDocsImages//Trgovina//Srpanj%202022_Euro_Smjernice%20za%20prilagodbu%20gospodarstva.pdf

[10] Petravić, D. (2022). Analiza nominalnih kriterija konvergencije za uvođenje eura u Republici Hrvatskoj (stanje pred uvođenje eura 1. siječnja 2023.). *Zbornik sveučilišta Libertas*, 7 (8), str. 63-84. doi: 10.46672/zsl.7.8.5.

[11] Tica, J., Nadoveza, O., Globan, T. (2016) Monetarna politika. U: Obadić, A. i Tica, J. (ur.). Gospodarstvo Hrvatske. Zagreb: Ekonomski fakultet Sveučilišta u Zagrebu, 2016. str. 247-286.

DODATAK

Anketni upitnik (2023.). *Stavovi dijela stanovništva o uvođenju eura u Republiku Hrvatsku*. Provedeno u lipnju 2023. godine.

Anketna pitanja:

1. **Spol:**
   a) muško
   b) žensko
   c) ostalo

2. **U kojoj dobi se nalazite?**
   a) 18-25
   b) 26-35
   c) 36-45
   d) 46-55
   e) 56-65
   f) iznad 65

3. **Koja je Vaša razina obrazovanja?**
   a) osnovna škola
   b) srednja škola
   c) fakultet
   d) magisterij
   e) doktorat znanosti

4. **Koji je Vaš trenutni radni status?**
   a) nezaposlen/a
   b) student/ica
   c) zaposlen/a na određeno
   d) zaposlen/a na neodređeno
   e) umirovljenik/ica

5. **Kojeg datuma je Republika Hrvatska pristupila Europskoj uniji te se ujedno time obvezala na zamjenu hrvatske kune eurom?**
   a) 7. siječnja 2013.
   b) 1. srpnja 2013.
   c) 1. siječnja 2015.
   d) 2. rujna 2017.

6. **Organizacija čiji je glavni cilj uvođenje eura u zemlje članice Europske unije naziva se:**
   a) Euroskupina
   b) Europska središnja banka
   c) Gospodarski i financijski odbor
   d) Ekonomska i monetarna unija

7. **Prema Vašem mišljenju, u koliko zemalja članica Europske unije je euro službena valuta?**
   a) 20
   b) 18
   c) 24
   d) 27

8. **Novčanice eura iste su u svim zemljama u kojima je euro službena valuta?**
   a) da
   b) ne
   c) ne znam

9. **Kovanice eura djelomično se razlikuju u zemljama u kojima je euro službena valuta?**
   a) da

b) ne
c) ne znam

10. Jeste li prije uvođenja eura u Republiku Hrvatsku koristili novčanice i kovanice eura?
a) da
b) ne

11. Smatrate li da je uvođenje eura pozitivno utjecalo na gospodarsko stanje u zemljama koje su ga uvele prije Republike Hrvatske?
a) da
b) ne
c) ne znam

12. Jeste li podržavali uvođenje eura kao službene valute u Republici Hrvatskoj?
a) da
b) ne
c) suzdržan

13. Smatrate li da je Republika Hrvatska bila spremna za uvođenje eura kao službene valute?
a) da
b) ne
c) ne znam

14. Smatrate li da je uvođenje eura kao službene valute u Republiku Hrvatsku imalo pozitivan utjecaj na Vas osobno?
a) da
b) ne
c) ne znam

15. Jeste li prije uvođenja eura kao službene valute u Republiku Hrvatsku štedjeli u eurima?
a) da
b) ne

16. Jeste li prije uvođenja eura kao službene valute u Republiku Hrvatsku obavljali novčane transakcije u euro novčanicama i kovanicama?
a) da
b) ne

17. Koristite li više kartično plaćanje nakon uvođenja eura u Republiku Hrvatsku?
a) da
b) ne

18. Do kojeg datuma traje obveza dvojnog iskazivanja cijena u Republici Hrvatskoj?
a) 31. prosinca 2023.
b) 31. prosinca 2024.
c) 1. siječnja 2024.
d) 1. studenog 2023.

19. Smatrate li da bi obvezu dvojnog iskazivanja cijena u Republici Hrvatskoj trebao produljiti?
a) da
b) ne
c) ne znam

20. Kupujete li više kod poslovnih subjekata koji su pristupili Etičkom kodeksu čiji je glavni cilj pouzdano i transparentno uvođenje eura u Republiku Hrvatsku ili ne obraćate pažnju na to prilikom kupovine?
a) da, preferiram kupnju kod poslovnih subjekata koji su pristupili Etičkom kodeksu
b) ne, ne obraćam pažnju je li poduzeće pristupilo Etičkom kodeksu priliko kupovine

21. Smatrate li da su svi poslovni subjekti poštovali fiksni tečaj konverzije ili su to neki iskoristili za neopravdano podizanje cijena?
a) smatram da je poštovan fiksni tečaj konverzije
b) smatram da su neki poslovni subjekti to iskoristili za neopravdano podizanje cijena

22. Smatrate li da je Republika Hrvatska trebala zamijeniti kunu eurom, s obzirom na stabilnost kune?
a) da
b) ne
c) ne znam

23. Kao glavnu prednost uvođenja eura u Republiku Hrvatsku, naveli bi ste: (mogući višestruki odabir)
a) uklanjanje valutnog rizika
b) manji trošak zaduživanja za domaće subjekte
c) smanjenje mogućnosti izbijanja bankovne i valutne krize
d) manji transakcijski troškovi
e) smanjenje naknada plaćanja
f) poticaj međunarodnoj razmjeni i suradnji
g) mogućnost pristupa europskim mehanizmima financijske pomoći

24. Kao glavni nedostatak uvođenja eura u Republiku Hrvatsku, naveli bi ste: (mogući višestruki odabir)
a) nedostatak slobode građana u izboru valute
b) gubitak samostalne monetarne politike
c) rast razina cijena

25. Smatrate li da je konverzija kune u euro doprinijela inflaciji, odnosno općem porastu cijena dobara i usluga?
a) da, smatram da je porasla razina inflacije nakon uvođenja eura
b) ne, smatram da je razina inflacije ostala ista kao i prije uvođenja eura

26. Jeste li se prilagodili na euro ili i dalje većinu cijena izraženu u eurima preračunavate u kune?
a) prilagodio/prilagodila sam se na euro i više ne gledam cijenu izraženu u kunama
b) i dalje cijene izražene u eurima preračunavam u kune kako bih stekao/stekla dojam o vrijednosti

27. Osjećate li nostalgiju za kunom ili ste se priviknuli na euro?
a) osjećam nostalgiju za kunom
b) priviknuo/priviknula sam se na euro

Review article / Pregledni rad

ETIČNOST U OGLAŠAVANJU MODNIH BRENDOVA NA DRUŠTVENIM MREŽAMA: PERCEPCIJA MLADIH

Doc. dr. sc. DIANA PLANTIĆ TADIĆ
Sveučilište VERN'
Palmotićeva ulica 82/1, 10000 Zagreb, Hrvatska
diana.plantic-tadic@vern.hr

Doc. dr. sc. JADRANKA IVANKOVIĆ
Sveučilište VERN'
Palmotićeva ulica 82/1, 10000 Zagreb, Hrvatska
jadranka.ivankovic@vern.hr

ANA KLASNIĆ
Sveučilište VERN'
Palmotićeva ulica 82/1, 10000 Zagreb, Hrvatska
aklasnic01@gmail.com

SAŽETAK

Oglašavanje je i nadalje nezaobilazan oblik promocijskih aktivnosti, o čemu govori prisutnost poruka oglašivača u svim raspoloživim masovnim medijima. Zahvaljujući razvoju digitalnih tehnologija, internet i društvene mreže nameću se kao prvi odabir oglašivača postupno potiskujući tradicionalne medije poput televizije, radija, novina i drugih. Sadržaj koji oglašivači plasiraju potencijalnim potrošačima otvara brojna pitanja o etičnosti oglašavanja. Etičnost u marketinškoj komunikaciji ponekad je dovedena u pitanje nastojanjima oglašivača da budu što drugačiji, originalniji i da pomiču granice, što je danas postao imperativ u mnoštvu promotivnih poruka, posebice kod modnih brendova.

U radu su prikazani rezultati kvantitativnog istraživanja koje je imalo za cilj utvrditi percepciju mladih o etičnosti u oglašavanju modnih brendova na društvenim mrežama. Istraživanje je provedeno na značajnom uzorku mladih u dobi od 18 do 35 godina u vezi oglašavanja na Instagramu, YouTubeu, Facebooku i TikToku kao najčešće korištenim društvenim mrežama.

Slijedom rezultata provedenog istraživanja uočava se da većina ispitanika obraća pažnju na etičnost modnih brendova, što posljedično utječe i na njihove odluke o kupnji pojedinog modnog brenda. Uz prikazane rezultate istraživanja, navedena su i ograničenja te smjernice za buduća istraživanja o etičnosti u oglašavanju.

KLJUČNE RIJEČI: društvene mreže, etičnost, modni brend, oglašavanje, percepcije mladih

ETHICS IN ADVERTISING FASHION BRANDS ON SOCIAL NETWORKS: THE PERCEPTION OF YOUNG PEOPLE

ABSTRACT

Advertising is still an unavoidable form of promotional activities, as evidenced by the presence of advertisers' messages in all available mass media. Thanks to the development of digital technologies, the Internet and social networks are emerging as the first choice of advertisers, gradually suppressing traditional media such as television, radio, newspapers, and others. The content that advertisers publish to potential consumers raises numerous questions about the ethics of advertising. Ethics in their marketing communication is sometimes called into question in their endeavors to be as different and original as possible, and to push the boundaries, as it has today become an imperative in many promotional messages, especially for fashion brands.

This paper presents the results of a quantitative research aimed at determining young people's perception of ethics in the advertising of fashion brands on social networks. The study was conducted on a significant sample of young people, aged 18–35, regarding advertising on Instagram, YouTube, Facebook, and TikTok, as the most used social networks.

According to the results of the conducted research, it is noticeable that the majority of participants pay attention to the ethics of fashion brands that consequently influence to their decisions about purchasing a particular fashion brand. Along with the research results, limitations and guidelines for future research on ethics in advertising are also discussed in the presented study.

KEYWORDS: ethics, advertising, social networks, fashion brands, young people's perception

1. UVOD

Ubrzani tehnološki razvoj ima odjek na svim područjima ljudskog djelovanja, tako i na marketing. Danas, više nego ikada, oglašavanje se kao nezaobilazan oblik promocijskih aktivnosti provodi korištenjem masovnih medija. Prvi odabir oglašivača postaje korištenje digitalnih tehnologija, interneta i društvenih mreža, a u drugi plan potiskuju se tradicionalni mediji poput televizije, radija i novina. S nekoliko klikova potencijalni kupci dobivaju željene informacije o proizvodima i uslugama iz udobnosti vlastitog doma, 24 sata dnevno i 7 dana u tjednu. Prema podacima Statiste iz siječnja 2023. najpopularnije društvene mreže u svijetu, rangirane prema broju mjesečno aktivnih korisnika, su Facebook (2.958 milijuna korisnika), YouTube (2.514 milijuna) te slijede WhatsApp i Instagram, svaki s 2.000 milijuna korisnika. Svaka od njih ima jedinstvene karakteristike i drugačiji skup korisnika (Al-Essa i Yahia, 2019). U Hrvatskoj je digitalno oglašavanje u 2022. godini vrijedilo 221,9 milijuna eura, što je rast od 1,3 % u odnosu na 2021. godinu, a navedeno se odnosi na vrijednost prodanih oglasa (Čizmić, 2023).

Društvene mreže imaju značajan udio u javnim internetskim aktivnostima, s njihovom popularnošću među korisnicima interneta povećano je i njihovo prihvaćanje od strane poduzeća kao sredstva oglašavanja za postojeće i potencijalne kupce te takva značajna količina oglasa donosi impresivno visoki prihod (Chinchanachokchai i de Gregorio, 2020). Stoga ne čudi da su trgovci brzo integrirali ove nove kanale u svoje komunikacijske strategije (Bianchi i sur., 2017).

Djafarova i Bowes (2021) naglašavaju kako je tržište mode vrlo konkurentno, a porast broja online trgovaca predstavlja značajne izazove za robne marke.

Svjetsko tržište sve je kompetitivnije te je imperativ svakoga brenda izgraditi snažan i dugotrajan odnos s potrošačima (Labaš i Rimac, 2020). Labaš i Koščević (2014, str. 202) upozoravaju kako se „oglašivački aparat i promidžbena industrija često služe manipulacijama kako bi se publiku *nagovorilo* na kupovinu i korištenje reklamiranoga proizvoda ili usluge, pa se nameće pitanje o etičnosti kao i istinitosti reklama". Oglašavanje na webu može ponekad promovirati i poruke koje nisu u suglasju s društvenim normama i vrijednostima (Wolin, Korgaonkar i Lund, 2002). Potreba da se putem oglašavanja prenese jedinstvena, kreativna i upečatljiva poruka ne smije ići u neprihvatljivom smjeru vrijeđanjem prava i omalovažavanja, već treba u prvom redu biti etična.

Svrha rada bila je istražiti stavove mlađe populacije o etičnosti u oglašavanju modnih brendova na društvenim mrežama. Temeljem određene svrhe rada identificirana su tri glavna cilja istraživanja kako slijedi:
C1. Dobiti uvid u percepciju mladih o porukama modnih brendova na društvenim mrežama;
C2. Utvrditi obraćaju li ispitanici pažnju na etičnost poruka modnih brendova;
C3. Utvrditi jesu li ispitanici spremni na promjenu odluke o kupnji proizvoda u slučaju neetičnog oglašavanja modnog brenda.

Nastavno postavljenim ciljevima istraživanja definirana je polazna pretpostavka da modni brendovi trebaju poštivati načelo etičnosti pri oglašavanju na društvenim mrežama jer je etičnost značajan kriterij za stjecanje povjerenja potrošača i stvaranje pozitivnog korporativnog imidža, ali ne i odlučujući čimbenik o kojem ovisi odluka mladih potrošača o kupnji proizvoda modnih brendova.

2. OGLAŠAVANJE NA DRUŠTVENIM MREŽAMA

Promocijski mix temeljni je koncept marketinga, poznat kao 4P (eng. *Product - Price - Place of distribution – Promotion*), odnosno proizvod, cijena, distribucija i promocija (Khan, 2014). Kotler i Armstrong definiraju oglašavanje, jedan od promocijskih oblika, kao „svaki plaćeni oblik neosobnog predstavljanja i promicanja ideja, robe ili usluge identificiranog sponzora" (2010, str. 96). Slično tome, Antolović i Haramija ističu da je „oglašavanje svaki plaćeni oblik prijenosa poruka s ciljem stvaranja utjecaja kod primatelja u kojem je izvor (oglašivač) obično prepoznatljiv" (2015, str. 32). Pri tome se AIDA model (eng. *Attention – Interest – Desire - Action*), poznat kao glavna teorija oglašavanja, često koristi za razumijevanje psihološkog ponašanja pojedinca, učinka marketinške komunikacije i potrošačkog ponašanja koje proizlazi iz medija (Song, Ruan i Jeon, 2021). Navedeni model objedinjuje četiri različite komponente: *pažnju*, dakle kupac postaje svjestan proizvoda, *interes* koji kupac razvija za proizvodom, *želju* koja se javlja za proizvodom te *akciju* iliti kupnju proizvoda (Rowley, 1998).

Društvene mreže postale su dio svakodnevne rutine korisnika i neizostavan resurs za donošenje potrošačkih odluka (Pentina i sur., 2018). Društvene mreže su web-mjesta koja omogućuju ljudima dijeljenje sadržaja koji su izradili sami korisnici, dakle prostor gdje mogu razgovarati jedni s drugima, dijeliti informacije te štoviše, nudi im se mogućnost izgradnje novih odnosa (Rohani i Ow, 2010). Slično tomu, Kaplan i Haenlein (2010) ističu kako se društveni mediji odnose na internetske platforme koje imaju za cilj omogućavanje korisnicima interakcije poput stvaranja i dijeljenja informacija te raspravljanja o idejama. Berthon i suradnici (2012)

definiraju društvene medije kao niz tehnoloških inovacija (hardvera i softvera) koji olakšavaju stvaranje jeftinog sadržaja, interakciju i interoperabilnost *online* korisnika.

Objave tekstova, slika i video zapisa putem društvenih mreža približavaju brojne proizvode i usluge postojećim i potencijalno novim kupcima. Osim toga, često je komunikacija dvosmjerna te se interakcija između kupca i oglašivača ili između više kupaca intenzivira, nerijetko i u realnom vremenu putem *chata*, komentara i slično. Interaktivna priroda društvenih medija i trenutna dostupnost vjerojatno je najvažnija razlika u odnosu na tradicionalne medije, što kao posljedicu ima pružanje potrošačima veće mogućnosti obrade podražaja u oglašavanju nego ranije (Ko, Cho i Roberts, 2005). Zbog svoje interaktivne prirode društveni mediji postali su moćan marketinški alat za brend menadžere (Park, Im i Kim, 2020).

Odmah nakon uvođenja na tržište društveni mediji su postali popularni, potrošači su ih vrlo brzo prihvatili te je njihova upotreba u porastu, kako u svijetu, tako i u Hrvatskoj (Kursan Milaković, Mihić i Boljat, 2020). Zadnjih godina zabilježen je brzi rast oglašavanja na platformama društvenih medija uz impresivan porast njihovih prihoda, ali istovremeno potrošači su sve više opterećeni količinom internetskog marketinga s kojim se susreću te koristite brojne načine za izbjegavanje takvih poruka (Chinchanachokchai i de Gregorio, 2020). Oglašavanje putem društvenih medija pruža mogućnost objedinjavanja dviju najdominantnijih, ali istovremeno suprotnih aspekata, a to su globalni doseg s jedne strane i personalizacija s druge (Okazaki i Taylor, 2013).

Društveni mediji mijenjaju razmjere i opseg međunarodnog oglašavanja, a pozitivni stavovi potrošača prema oglašavanju na društvenim mrežama povećavaju njihovu aktivnost i interakciju na tim medijima (Johnston i sur., 2018). Digitalni mediji stvaraju okruženje koje omogućava modnim brendovima direktnu komunikaciju sa svojim potrošačima (Savić i Frfulanović-Šomođi, 2019).

3. MODNI BRENDOVI I DRUŠTVENE MREŽE

Brend je složen fenomen te među članovima akademske zajednice ne postoji zajedničko jedinstveno razumijevanje ovog pojma (Maurya i Mishra, 2012). Američka marketinška asocijacija (AMA, 2023) definira brend kao naziv, pojam, dizajn, simbol ili bilo koje drugo obilježje koje identificira robu ili uslugu jednog prodavatelja u odnosu na druge.

U modernim industrijskim društvima brend karakteriziraju društvene i simboličke vrijednosti te se pomoću brenda izražavaju moralna načela kao što su prestiž, elegancija, poštenje (Barroso, 2019). Temeljem proučavane literature Lušić (2022) sumira kako brend karakteriziraju prepoznatljivost, kvaliteta i imidž te jasno osmišljeno i smisleno plasiranje u javnost. Modni proizvodi imaju snažno simboličko značenje jer omogućavaju izražavanje identiteta svakog pojedinca koji ih koristi (Han & Choi, 2019). Oglašavanje u modnoj industriji pomaže ostvarivanju profita te je zaslužno za uzdizanje mode do mitskog statusa (Spalletta, & Ugolini, 2016). Modni brendovi su u velikoj mjeri usmjereni mladima te se kao najčešći kanal dopiranja do njih koriste društvene mreže.

Cilj svakog oglašavanja je zadržati postojeće potrošače i steći nove. Brojna globalna poduzeća koriste društvene mreže u sve većoj mjeri kao platforme za oglašavanje (Hatzithomas, Fotiadis i Coudounaris 2016), a modna poduzeća nisu izuzetak. Thomas i Peters (2011) naglašavaju kako je oglašavanje na društvenim mrežama područje sve većeg interesa za istraživače koji se

bave modnim marketingom, a Chu i Seock (2020) ističu kako bi modna poduzeća mogla digitalno oglašavanje uzeti u obzir kao značajnije i autentičnije od tradicionalnog oglašavanja budući da digitalno oglašavanje ima izniman potencijal u kreiranju sadržaja na društvenim mrežama i moć pridobivanja pažnje potrošača. Potrošači koji imaju pozitivan stav prema oglašavanju na društvenim mrežama vjerojatno će reagirati povoljno te će kupiti proizvod koji se oglašava na društvenim mrežama (Boateng i Okoe, 2015). Danas, platforme društvenih medija postale su primarni izvor informacija za potrošače i jedan od najmoćnijih marketinških alata za modna poduzeća te je Instagram prepoznat kao najveći utjecajan izvor kojim se dobiva uvid u modu (Chu i Seock, 2020).

Svijest o brendu je važna utoliko što utječe na ponašanje potrošača. Keum i suradnici (2004) naglašavaju da su osobe koje su svjesne postojanja brenda one koje visoko cijene brendove i iskazuju interes za učenje o brendovima putem komercijalnih medijskih izvora. Takva usmjerenost na kupovinu može utjecati na to kako potrošači koji su svjesni brendova prate oglase na društvenim medijima, što utječe na njihove stavove prema oglašavanju u medijima (Chu, Kamal i Kim, 2013). Prema rezultatima istraživanja koje su proveli Boateng i Okoe (2015), i korporativni ugled kritičan je za potrošače jer odluka o kupnji proizvoda ili poduzimanje pozitivne radnje prema proizvodima koji se oglašavaju na društvenim mrežama ovisi o njemu. Stoga, poduzeća trebaju voditi računa o tome kakvu reputaciju imaju, a ona se gradi, među ostalim, i putem etičnih poruka.

Ponašanje potrošača može biti determinirano i racionalnim i emocionalnim utjecajima, ali oni djeluju na različite načine te zasada nema konsenzusa među stručnjacima koji od njih je učinkovitiji (Grigaliunaite i Pileliene, 2016). Pozivanje na emocije je uobičajena praksa u modnoj industriji, a takav način oglašavanja proširio se i na druge industrije (Panda, Panda i Mishra, 2013). Nadalje, emocionalno oglašavanje utječe na reakcije kupaca na oglase tako da povećava njihovu pozornost i utječe na stavove o brendu (Panda, Panda i Mishra, 2013). U istraživanju koje su provele autorice Dlačić, Ribarić i Barna (2016) pokazalo se kako kod modne odjeće seksipil djeluje poticajno na emocije pri čemu veći utjecaj ima na pozitivne emocije, ali istovremeno naglašavaju da kod korištenja emocionalnih komponenti komunikacijske poruke treba biti oprezan jer iako u načelu ne utječu na pojavu negativnih emocija, korištenje seksepila u primjeru modne odjeće u značajnoj mjeri djeluje kontra produktivno. Grigaliunaite i Pileliene (2016) navode kako emocionalno privlačniji oglas i pozitivniji stav ne dovode nužno i do povećanja razine kupovne namjere potrošača.

U oglašavanju se koriste i negativne emocije kao bi se potencijalnog kupca zabrinulo, zastrašilo ili čak šokiralo. Budući da takav oglas može izazvati pretjeranu razinu tjeskobe koja može predstavljati prijetnju psihološkoj dobrobiti kupaca (Panda, Panda i Mishra, 2013), neophodno je razmotriti etičnost uporabe takvih oglasa. Željeni efekt privlačenja kupaca mogao bi u takvom slučaju izostati, štoviše moglo bi doći do odbojnosti prema određenom proizvodu ili brendu.

4. ETIČNOST U OGLAŠAVANJU

Etika je znanost o moralu i nastoji objasniti moralni aspekt ljudskog ponašanja, a „etika u oglašavanju odnosi se na ponašanje organizacija u njihovom nastupu na tržištu, posebno provedbi spleta komuniciranja kojeg definiramo kao oglašavanje“ (Antolović i Haramija, 2015, str. 118). Etika oglašavanja je razmjerno mlada etička disciplina, uglavnom se shvaća kao primijenjena etika te je zanemarivo prisutna u znanstvenoj literaturi na hrvatskom jeziku i u

domaćim znanstvenim raspravama (Žanetić, 2014). Dvojbe o tome što je etično (dobro), a što je neetično (loše) proizlaze iz proturječja poslovne prakse jer interesi pojedinca, poduzeća i društva u cjelini nisu usuglašeni (Martinović i Jurković Majić, 2009). Kako bi regulirala poslovanje i osigurala etičnost, poduzeća nerijetko osmišljavaju etičke kodekse ponašanja. Unatoč tome, u svojim nastojanjima da čim bolje plasiraju proizvod ponekad se dogodi da se brendovi oglašavaju na neprimjeren način. Bilo slučajno ili namjerno, posljedice su prisutne. Sadržaji koji oglašivači plasiraju potencijalnim potrošačima otvaraju brojna pitanja o etičnosti oglašavanja jer u svojim nastojanjima da budu što drugačiji i originalniji, prelaze granice općeprihvatljivoga. Antolović i Haramija (2015, str. 119) navode kako se propitivanja o etičnosti oglašavanja „najčešće odnose na preuveličane tvrdnje i prikrivanje činjenica, zlouporabu intelektualnog vlasništva te načina korištenja seksualnih motiva i motiva djece".

Negativan apel oglašavanja putem šokantnih oglasa koriste brojna poduzeća, a Martinović i Jurković Majić (2009) navode primjer Benettona koji je na plakatima prikazivao npr. afričkog gerilca koji drži kalašnjikov i kost ljudske noge, krvavo novorođenče s pupčanom vrpcom, svećenika i časnu sestru koji se ljube, zatvorenike osuđene na smrt ili krvavu uniformu hrvatskog vojnika. Talijanski brend Diesel također se koristio šokantnim oglašavanjem (Machova, Huszárik, & Toth, 2015) jer je za promociju koristio asocijacije povezane s maloljetničkim nasiljem i prostitucijom (Spalletta, & Ugolini, 2016).

5. METODOLOGIJA I REZULTATI ISTRAŽIVANJA

Kvantitativno istraživanje[1], dakle *online* anketiranje provedeno je uz pomoć elektroničkog anketnog upitnika na mlađoj populaciji u dobi od 18 do 35 godina. Anketni upitnik je sadržavao eliminacijska pitanja vezano uz dob ispitanika i korištenje društvenih mreža, stoga je od ukupno pristupljenih 312 ispitanika definiran konačan uzorak od 303 ispitanika nakon eliminacijskih pitanja. Kao što je vidljivo u Tablici 1, većina ispitanika bile su osobe mlađe od 24 godine, ženskog spola te pripadnici studentske populacije.

Tablica 1. Demografske karakteristike ispitanika (N=303)

Demografske karakteristike		**frekvencija**	**postotak (%)**
Dob	18-23	190	62,7
	24-29	79	26,1
	30-35	34	11,2
UKUPNO		**303**	**100,0**
Spol	muško	46	15,2
	žensko	256	84,5
	ostalo	1	0,3
UKUPNO		**303**	**100,0**
Radni status	student/ica	215	70,9
	zaposlen/a	82	27,1
	nezaposlen/a	4	1,3
	ostalo	2	0,7
UKUPNO		**303**	**100,0**

Izvor: Autorice

[1] U radu su analizirani rezultati istraživanja djelomično provedenog za potrebe izrade završnog rada studentice Ane Klasnić.

Na pitanje koje društvene mreže najčešće koriste ispitanici su imali mogućnost višestrukog odgovora (Slika 1). Najčešće korištena društvena mreža prema odgovorima ispitanika je Instagram (284 odgovora), You Tube (232), Facebook (200), zatim TikTok (147) te Twitter (20 odgovora). Pod rubrikom „ostalo“ ispitanici su navodili i WhatsApp, BeReal, Snapchat, Pinterest, LinkedIn, Reddit, ali u znatno manjoj mjeri.

Slika 1. Korištene društvene mreže

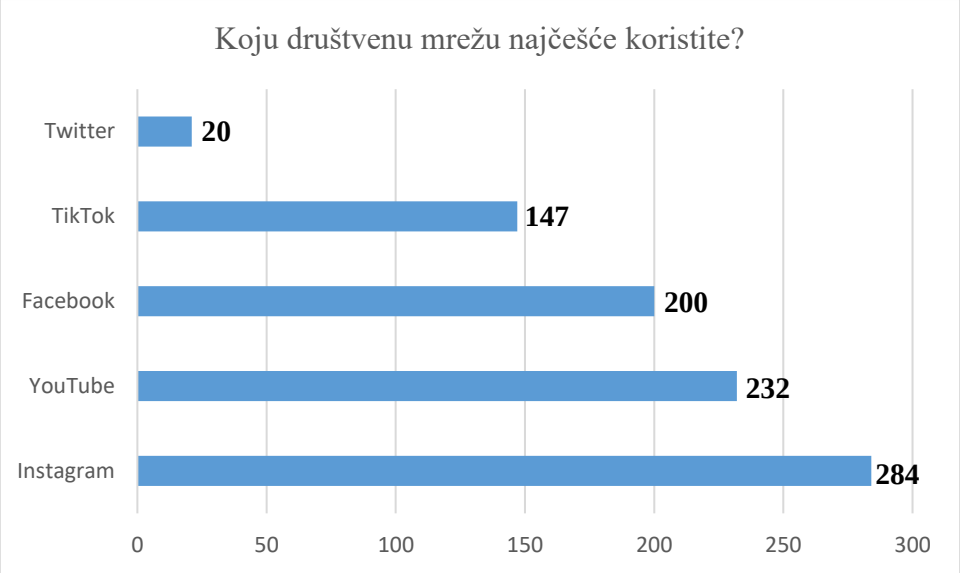

Izvor: Autorice

Odgovori ispitanika na pitanje o najčešćim aktivnostima na društvenim mrežama prikazani su na Slici 2 (također uz mogućnost višestrukog odgovora). Najčešće aktivnosti ispitanika na društvenim mrežama su: a) komuniciranje s prijeteljima (250 odgovora), b) pregledavanje tuđih fotografija (190), c) čitanje vijesti (190), d) čitanje komentara (162) te e) objavljivanje vlastitih fotografia (141).

Slika 2. Aktivnosti ispitanika na društvenim mrežama

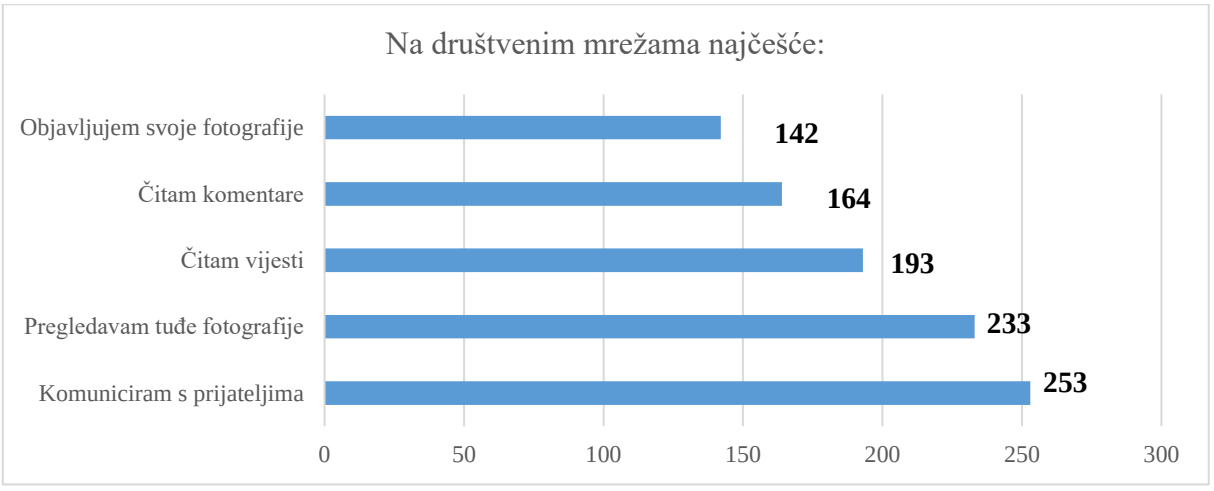

Izvor: Autorice

Slika 3 prikazuje odgovore ispitanika vezano uz vrijeme koje provode na društvenim mrežama. Najveći je udio ispitanika koji provode na društvenim mrežama od tri do pet sati (42,9%), slijedi udio ispitanika koji na društvenim mrežama provode od jednog do dva sata (41,9%), dok je (8,6%) izjavilo da provodi i više od pet sati dnevno na društvenim mrežama, dok svega 6,6 % ispitanika provodi manje od jednog sata dnevno na društvenim mrežama.

Slika 3. Vrijeme provedeno na društvenim mrežama

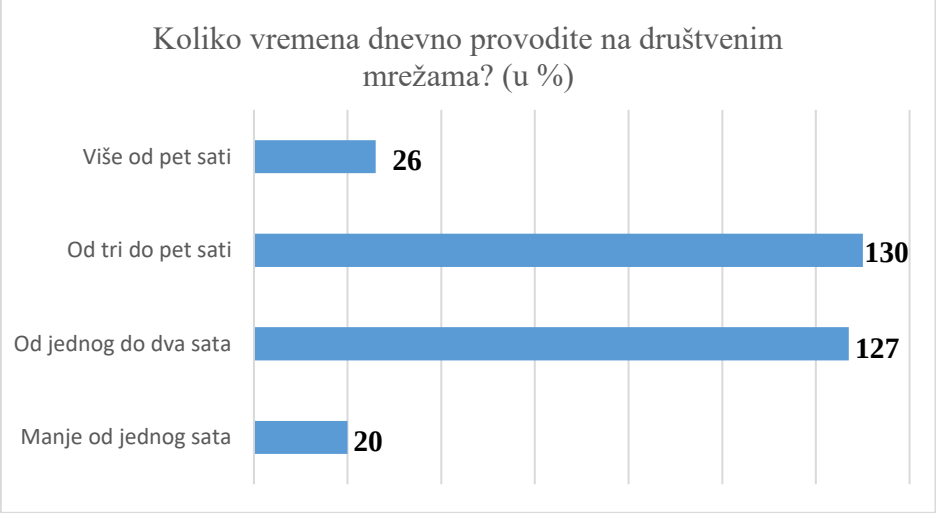

Izvor: Autorice

U sljedećem pitanju otvorenog tipa ispitanici su trebali navesti tri asocijacije na riječ etičnost. Najzastupljeniji odgovori su moral sa 123 odgovora, na drugom mjestu nalazi se odgovor pravda/pravednost (98) te na trećem mjestu poštenje (73). Među zastupljenijim odgovorima su bili i povjerenje, pristojnost, društvena prihvatljivost i ispravnost.

Slika 4 prikazuje odgovore ispitanika na pitanje u vezi karakteristika etičnih oglasa (uz mogućnost višestrukog odabira). Najveći broj ispitanika odabrao je ponuđeni odgovor da je etični oglas onaj koji ne vrijeđa nikoga (262), koji ne potiče diskriminaciju (255), poštuje različitost (241), ne ismijava nikoga (223) i na posljetku onaj koji uvažava konkurente (161 odgovor).

Slika 4. Percepcija mladih o pojmu etičnog oglasa

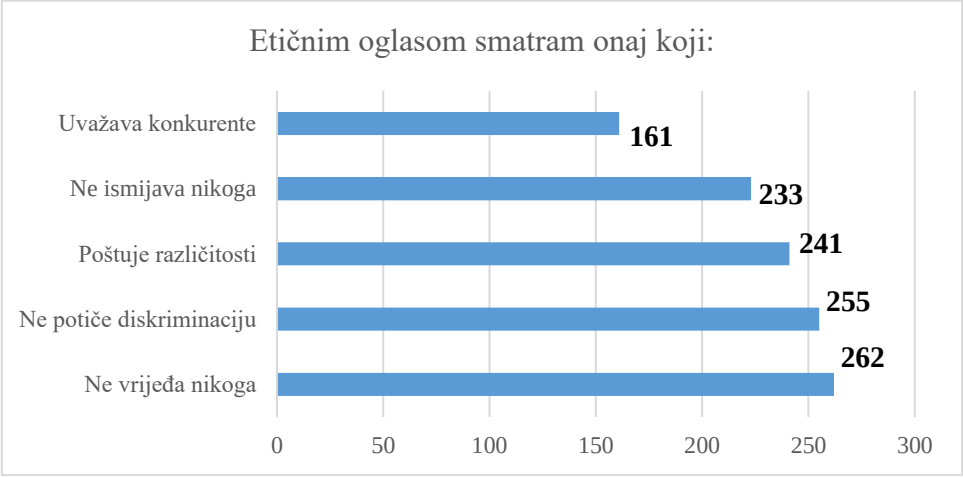

Izvor: Autorice

Kako bi se utvrdili stavovi ispitanika o važnosti mode i etičnog oglašavanja na društvenim mrežama i namjeri kupovine ukoliko se proizvod oglašava na neetičan način, ponuđene su četiri tvrdnje, kao što je prikazano u Tablici 2. Ispitanici su svoj stupanj slaganja s ponuđenim tvrdnjama trebali ocijeniti na skali Likertovog tipa (od *1 uopće se ne slažem,* do *5 u potpunosti se slažem*).

Tablica 2. Stavovi mladih o etičnosti u oglašavanju na društvenim mrežama

Tvrdnje	**1 (%)**	**2 (%)**	**3 (%)**	**4 (%)**	**5 (%)**	**Aritmetička sredina**	**Standardna devijacija**
Smatram da je važno oglašavati se putem društvenih mreža na etičan način.	2,3	3,3	6,3	19,1	69,0	4.49	0.92
Etičnost oglašavanja utječe na moju odluku o kupovini određenog proizvoda.	1,32	9,9	9,6	30,6	28,7	3.86	0.98
Ukoliko mi se neki proizvod jako sviđa, ali oglašavanje tog brenda smatram neetičnim, neću kupiti proizvod.	8,3	16,2	29,0	27,1	19,5	3.33	1.20
Moda mi je vrlo važna.	5,6	11,2	28,1	31,0	24,1	3.57	1.14

Izvor: Autori

Najvišu srednju ocjenu ima tvrdnja *Smatram da je važno oglašavati se putem društvenih mreža na etičan način* (AS = 4,49) uz najmanje prosječno odstupanje svih odgovora od aritmetičke sredine (SD = 0,92). Najniže ocjenjena tvrdnja jest *Ukoliko mi se neki proizvod jako sviđa, ali oglašavanje tog brenda smatram neetičnim, neću kupiti proizvod* (AS =3,33), Prema dobivenim rezultatima, može se zaključiti da znatan broj ispitanika etičnost u oglašavanju na društvenim mrežama smatra iznimno važnim, ali ako im se proizvod jako sviđa, odluku o kupnji istog donijet će i na osnovu nekih drugih kriterija te etičnost modnog brenda neće biti odlučujuća.

Od ispitanika se tražilo i da se izjasne mogu li povezati neetično oglašavanje na društvenim mrežama s određenim modnim brendom, gdje je svega 16,8 % ispitanika potvrdno odgovorilo i navelo, primjerice, Balenciagu, Niveu i Benneton, 38,3 % nije bilo sigurno, a 44,9 % je odabralo negativan odgovor.

Kako je uočljivo sa Slike 5, najčešća reakcija ispitanika je da zbog neetičnog oglasa odlučuju ne kupiti taj proizvod (167 odgovora), ne poduzimati ništa (127 odgovora), prijaviti takav oglas (74 odgovora), proslijediti ga ostalima uz negativnu kritiku (60 odgovora) te ostaviti negativan komentar (19 odgovora). Ispitanici su u ovom pitanju imali mogućnost višestrukog odabira.

Slika 5. Reakcije ispitanika na neetično oglašavanje

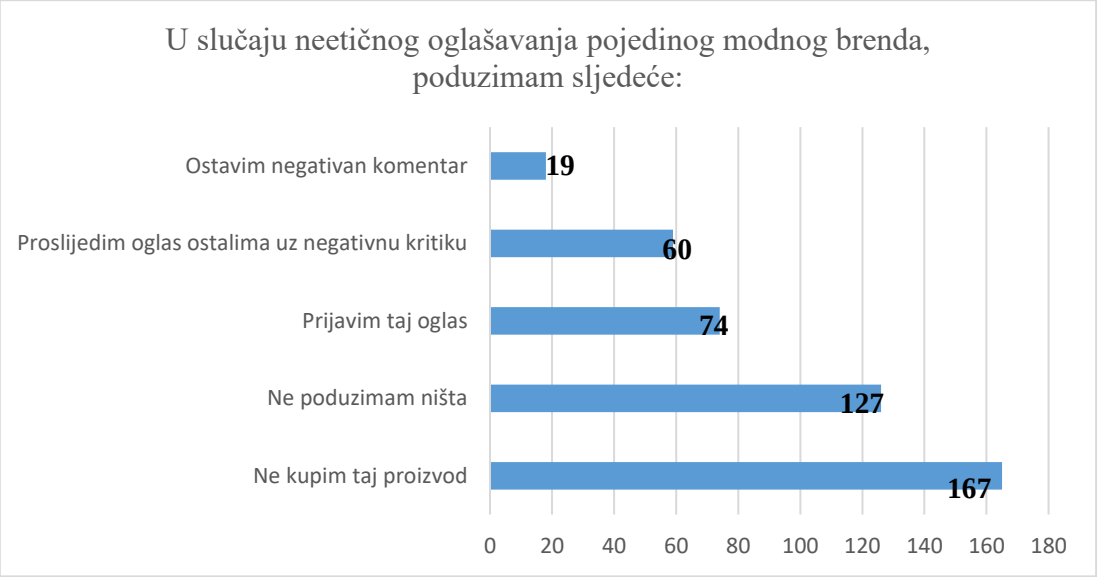

Izvor: Autorice

Slijedom rezultata provedenog istraživanja uočava se da većina ispitanika koristi društvene mreže, najčešće za komuniciranje s prijateljima i/ili za pregledavanje tuđih fotografija. Najčešće korištene društvene mreže su Instagram, YouTube i Facebook te znatan broj ispitanika provodi 3-5 ili 1-2 sata na društvenim mrežama. Glede percepcije mladih, ispitanici razumiju kakav je etičan oglas i važnost etike u oglašavanju na društvenim mrežama. Međutim, ako im se proizvod jako sviđa, odluku o kupovini istog donijet će i na osnovu nekih drugih kriterija, a ne samo na osnovi etičnosti oglašavanja. Što se tiče poznavanja neetičnog oglašavanja modnih brendova, velika većina ispitanika odgovorila je negativno ili su se izjasnili da nisu upoznati. Postupanje mladih u slučajevima neetičnog oglašavanja u najvećoj mjeri odnosi se na odustajanje od kupnje oglašavanog proizvoda ili nepoduzimanje nikakve radnje, a u manjoj mjeri na prijavu oglasa, prosljeđivanje oglasa drugima uz negativnu kritiku ili ostavljanje negativnog komentara, čime dokazuju da obraćaju značajnu pažnju na etičnost poruka modnih brendova.

6. ZAKLJUČAK I IMPLIKACIJE

Razvoj tehnologije ima implikacije na marketing, a to se među ostalim, ogleda i u oglašavanju putem društvenih mreža. U ovom radu prikazani su rezultati istraživanja o percepciji mladih o etičnosti u oglašavanju modnih brendova na društvenim mrežama.

Dobiveni rezultati sugeriraju da modni brendovi trebaju koristiti društvene mreže za oglašavanje svojih proizvoda vodeći računa o etičnosti poruka koje upućuju korisnicima. Naime, rezultatima istraživanja potvrđena je polazna pretpostavka da modni brendovi trebaju poštivati etičnost pri oglašavanju na društvenim mrežama jer je etičnost važan čimbenik za stvaranje imidža i lojalnosti potrošača, ali ipak nije čimbenik o kojem ovisi odluka mladih potrošača o kupnji proizvoda tih modnih brendova.

Rezultati bi mogli koristiti marketinškim stručnjacima u boljem razumijevanju etičnog oglašavanja kako bi unaprijedili korištenje društvenih mreža kao važnog poslovnog alata.

Poduzeća koja koriste oglašavanje na društvenim mrežama moraju promovirati etičnost kako bi ulijevala povjerenje svojim kupcima i izgradila pozitivan korporativni imidž.

Rad ima određena ograničenja. U istraživanju je korišten prigodni uzorak te se dobiveni rezultati uzimaju kao indicije. U daljnjim istraživanjima mogli bi se ispitati stavovi starijih ispitanika jer postoji mogućnost različite procjene neetičnosti u oglašavanju, a kombinacija kvalitativnog i kvantitativnog pristupa dala bi pouzdanije, preciznije i potpunije informacije koje bi osigurale bolji i dublji uvid u proučavanu tematiku.

REFERENCE

[1] Al-Essa, M; Yahia, I. B. (2019). Success and failure factors of social media integration - insights from business experience. *International Journal of Electronic Marketing and Retailing,* 10 (2), str. 118-129.

[2] AMA (2023). Definition of Brand, https://www.ama.org/the-definition-of-marketing-what-is-marketing/, preuzeto: [17. kolovoza 2023]

[3] Antolović, K; Haramija, P. (2015). *Odgovorno oglašavanje: pravo i etika u tržišnom komuniciranju.* K&K Promocija i HURA, Zagreb, Hrvatska.

[4] Barroso, P. (2019). Rhetoric of affections: advertising, seduction and truth. *Media & Jornalismo,* 19 (34), str. 143-154.

[5] Berthon, P. R; Pitt, L. F; Plangger, K; Shapiro, D. (2012). Marketing meets Web 2.0, social media, and creative consumers: implications for international marketing strategy. *Business Horizons,* 55 (3), str. 261-271.

[6] Bianchi, C; Andrews, L; Wiese, M; Fazal-E-Hasan, S. (2017). Consumer intentions to engage in s-commerce: a cross-national study. *Journal of Marketing Management,* 33 (5/6), str. 464-494.

[7] Boateng, H; Okoe, A. F. (2015). Consumers' attitude towards social media advertising and their behavioural response. *Journal of Research in Interactive Marketing,* 9 (4), str. 299–312.

[8] Chinchanachokchai, S; de Gregorio, F. (2020). A consumer socialization approach to understanding advertising avoidance on social media. *Journal of Business Research,* 110, *str*. 474–483.

[9] Chu, S.-C.; Kamal, S.; Kim, Y. (2013). Understanding consumers' responses toward social media advertising and purchase intention toward luxury products. *Journal of Global Fashion Marketing,* 4 (3), 158–174.

[10] Chu, S.-C; Seock, Y.-K. (2020). The Power of Social Media in Fashion Advertising. *Journal of Interactive Advertising,* 20 (2), str. 93–94.

[11] Čizmić, M. (2023). Zimo.dnevnik.hr, https://zimo.dnevnik.hr/clanak/digitalno-oglasavanje-u-hrvatskoj-raste-iz-godine-u-godinu-u-2022-iznosilo-gotovo-222-milijuna-eura---789720.html, preuzeto: [26. kolovoza 2023]

[12] Djafarova, E; Bowes, T. (2021). Instagram made Me buy it: Generation Z impulse purchases in fashion industry. *Journal of Retailing and Consumer Services,* 59, 102345.

[13] Dlačić, J; Ribarić, I; Barna, M. (2016). Pobuđivanje emocija kod potrošača: utjecaj kategorije proizvoda. *Ekonomska misao i praksa,* 25 (1), str. 47-72.

[14] Grigaliunaite, V; Pileliene, L. (2016). Emotional or Rational? The Determination of the Influence of Advertising Appeal on Advertising Effectiveness. *Scientific Annals of Economics and Business,* 63 (3), str. 391–414.

[15] Han, T.-I; Choi, D. (2019). Fashion Brand Love: Application of a Cognition–Affect–Conation Model. *Social Sciences,* 8 (9), str. 1-14.

[16] Hatzithomas, L; Fotiadis, T. A; Coudounaris, D. N. (2016). Standardization, Adaptation, and Personalization of International Corporate Social Media Communications. *Psychology & Marketing*, 33 (12), str. 1098–1105.
[17] Johnston, W. J; Khalil, S; Le, A. N. H; Cheng, J. M.-S. (2018). Behavioral Implications of International Social Media Advertising: An Investigation of Intervening and Contingency Factors. *Journal of International Marketing,* 26 (2), str. 43–61.
[18] Kaplan, A; Haenlein, M. (2010). Users of the World, Unite! The Challenges and Opportunities of Social Media. *Business Horizons,* 53 (1), str. 59-68.
[19] Khan, M. T. (2014). The Concept of 'Marketing Mix' and its Elements. *International Journal of Information, Business and Management,* 6 (2), str. 95 – 107.
[20] Ko, H; Cho, C.-H; Roberts, M. S. (2005). Internet Uses and Gratifications: A Structural Equation Model of Interactive Advertising. *Journal of Advertising,* 34 (2), str. 57–70.
[21] Kotler, P; Armstrong, G. M. (2010). *Principles of marketing*. Pearson Education India.
[22] Kursan Milaković, I; Mihić, M; Boljat, I. (2020). Consumer Attitudes Towards Social Network Advertising: Predictors and Outcomes. *Market-Tržište,* 32 (Sp. Issue), str. 83-97.
[23] Keum, H; Devanathan, N; Deshpande, S; Nelson, M. R; Shah, D. V. (2004). The citizenconsumer: Media effects at the intersection of consumer and civic culture. *Political Communication,* 21, str. 369– 392.
[24] Labaš, D; Koščević, K. (2014). Etička pitanja i manipulacija u oglašavanju. *Mostariensia,* 18 (1-2), str. 201-230.
[25] Labaš, D; Rimac, S. (2020). Brendovi, mladi i kriza emocionalne pismenosti. *South Eastern European Journal of Communication*, 2 (1), str. 49-63.
[26] Lušić, I. (2022). Ladarice – od ljubavi do kulturnog brenda. *Etnološka istraživanja,* 27, str. 154-167.
[27] Machova, R; Huszárik, E; Toth, Z. (2015). The role of shockvertising in the context of various generations. *Problems and Perspectives in Management,* 13 (1), str. 104-112.
[28] Martinović, M; Jurković Majić, O. (2009). Etički izazovi globalnom marketingu. *Obnovljeni život,* 64 (1), str. 33-51.
[29] Maurya, U. K; Mishra, P. (2012). What is a brand? A Perspective on Brand Meaning. *European Journal of Business and Management*, 4 (3), str. 122 – 133.
[30] Okazaki, S; Taylor, C. R. (2013*).* Social media and international advertising: theoretical challenges and future directions. *International Marketing Review,* 30 (1), str. 56–71.
[31] Panda, T. K; Mishra, K. (2013). Does Emotional Appeal Work in Advertising? The Rationality Behind Using Emotional Appeal to Create Favorable Brand Attitude. *The IUP Journal of Brand Management,* 10 (2), str. 7-23.
[32] Park, M; Im, H; Kim, H.-Y. (2020). "You are too friendly!" The negative effects of social media marketing on value perceptions of luxury fashion brands. *Journal of Business Research,* 117, str. 529-542.
[33] Pentina, I; Guilloux, V; Micu, A. C. (2018). Exploring Social Media Engagement Behaviors in the Context of Luxury Brands. *Journal of Advertising,* 47 (1), str. 55–69.
[34] Rohani, V. A.; Ow, S. H. (2010). On Social Network Websites: Definition, Features, Architectures and Analysis Tools. *Journal of Advances in Computer Research,* 1, str. 3-11.
[35] Rowley, J. (1998). Promotion and marketing communications in the information marketplace. *Library Review,* 47 (8), str. 383–387.
[36] Savić, M; Frfulanović-Šomođi, D. (2019). Generacija Y i lojalnost modnim brendovima. *Tekstilna industrija,* 3, str. 39-44.

[37] Song, H; Ruan, W. J; Jeon, Y. J. J. (2021). An integrated approach to the purchase decision making process of food-delivery apps: Focusing on the TAM and AIDA models. *International Journal of Hospitality Management,* 95, 102943.
[38] Spalletta, M; Ugolini, L. (2016). Fashion/Social Advertising. What Happens When Fashion Meets Social Issues. *Commons. Revista De Comunicación Y Ciudadanía Digital*, 3 (1), str. 119-160.
[39] Statista (2023). https://www.statista.com/statistics/272014/global-social-networks-ranked-by-number-of-users/, preuzeto: [31. srpnja 2023]
[40] Thomas, J. B; Peters, C. O. (2011). Which Dress Do You Like? Exploring Brides' Online Communities. *Journal of Global Fashion Marketing,* 2 (3), str. 148–160.
[41] Wolin, L. D; Korgaonkar, P; Lund, D. (2002). Beliefs, attitudes and behavior towards Web advertising. *International Journal of Advertising*, 21, str. 87–113.
[42] Žanetić, I. (2014). Etika oglašavanja – problemi definiranja i razgraničenja od srodnih disciplina. *Filozofska istraživanja,* 34 (1-2), str. 213-228.

Professional paper / Stručni rad

DIGITALNA TRANSFORMACIJA KNJIGOVODSTVENOG SERVISA U KONTEKSTU ONLINE DOHVATA I AUTOMATSKE OBRADE e-RAČUNA i e-IZVODA BANKE

STJEPAN VIDAČIĆ
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
stjepan.vidacic@foi.hr

SAŽETAK

Istraživanje i razvoj informacijskog sustava (IS) knjigovodstvenih servisa (KS) zauzelo je značajno mjesto u informatičkoj praksi i radovima autora ovog rada u posljednjih 15-tak godina. Zadnji rad iz ove domene (2019) bavio se istraživanjem mogućnosti unaprjeđenja odnosa na relaciji KS – klijenti uz pomoć uvođenja web-izvještajnog sustava za klijente, što je osnova digitalne transformacije procesa izvještavanja klijenata KS-a o stanju njihovog financijskog knjigovodstva. Međutim, ključni problemi klasičnog prikupljanja izvornih dokumenata klijenata KS-a s podacima potrebnim za knjiženje (ulazni računi, izlazni računi, izvodi banke) ostali su i dalje isti: različiti modeli fizičke ili online dostave dokumenata ili sintetičkih podataka od strane klijenata u KS, komunikacija s bankama, kašnjenje klijenata u dostavi dokumenata, neažurnost podataka klijenata u okviru IS-a KS-a u realnom vremenu, klasična arhiva dokumenata, niska produktivnost djelatnika KS-a i drugo. Uvođenje sustava e-Računa (obavezno u sustavu javne nabave od 2019., a moguće obavezno i za sve tvrtke od 2024.) i pozicioniranje ovlaštenih Informacijskih posrednika za e-Račune na tržištu elektroničkih usluga, od kojih neki napredniji nude nove usluge (npr. e-Plati), otvorilo je prostor i mogućnosti za nova unaprjeđenja IS-a KS-a koja mogu dovesti do gotovo potpune digitalne transformacije IS-a KS-a.

U navedenom kontekstu u radu je prezentirano rješenje i očekivani efekti integracije IS-a KS-a s određenim metodama-uslugama odabranog Informacijskog posrednika koja omogućuje: automatski online dohvat i obradu e-Računa klijenata, automatski online dohvat i obradu e-Izvoda banaka klijenata, memoriranje sadržaja dohvaćenih dokumenata u bazu podataka u različitim formatima (TXT, XML, PDF), isključenje razmjene dokumenata KS – klijent u fizičkom obliku, te digitalnu arhivu dokumenata u bazi podataka bez datoteka dokumenata.

KLJUČNE RIJEČI: knjigovodstveni servis, informacijski posrednik, e-Račun, e-Izvod banke, digitalna transformacija, digitalna arhiva

DIGITAL TRANSFORMATION OF ACCOUNTING SERVICES IN THE CONTEXT OF ONLINE RECEIVING AND AUTOMATIC PROCESSING e-INVOICE and e-BANK STATEMENTS

ABSTRACT

Research and development of the information system (IS) of bookkeeping services (KS) has taken a significant place in IT practice and the works of the author of this paper in the last 15 years or so. The last paper from this domain (2019) dealt with research into the possibility of improving relations between KS and clients with the help of introducing a web-reporting system for clients, which is the basis of the digital transformation of the process of reporting to KS clients about the state of their financial accounting. However, the key problems of the classic collection of original documents of KS clients with data necessary for posting (incoming invoices, outgoing invoices, bank statements) remained the same: different models of physical or online delivery of documents or synthetic data by clients in KS, communication with banks, client delays in document delivery, non-updated client data within KS IS in real time, classic document archive, low productivity of KS employees and others. The introduction of the e-Invoice system (mandatory in the public procurement system from 2019, and possibly mandatory for all companies from 2024) and the positioning of authorized information intermediaries for e-Invoices on the market of electronic services, some of which are more advanced offering new services (e.g. e-Pay), opened space and possibilities for new improvements to the KS IS that can lead to an almost complete digital transformation of the KS IS.

In the aforementioned context, the paper presents the solution and expected effects of the KS IS integration with certain methods-services of an information intermediary, which enables: automatic online retrieval and processing of clients' e-Invoices, automatic online retrieval and processing of clients' e-Bank statements, memorization of the content of retrieved documents in the database in various formats (TXT, XML, PDF), exclusion of the exchange of KS - client documents in physical form, and a digital archive of documents in the database without document files.

KEYWORDS: bookkeeping service, information intermediary, e-Invoice, e-Bank statement, digital transformation, digital archive

1. UVOD

Cilj ovog rada je prezentacija rezultata nastavka istraživanja iz izvora [9] informacijskog sustava (IS) knjigovodstvenog servisa (KS), u kontekstu razvoja i primjene sustava e-Računa, a posebno razvoja novih tehnologija i e-Servisa (e-Plati [17]) koje gospodarstvu pružaju Informacijski posrednici u RH [14], [15], temeljem čega su otvorene nove mogućnosti integracije programskih rješenja u okviru IS-a KS-a sa e-Servisima, koje omogućuju značajan iskorak u smjeru realizacije digitalne transformacije [12], [13] poslovanja KS-a na visokoj razini.

Na slici 1. prikazan je dopunjeni sustavsko dinamički (SD) strukturni dijagram prezentiran u izvoru [9], koji prikazuje zatvorenu pozitivnu povratnu petlju i uzročno posljedične veze između pet ključnih procesa unutar IS-a KS-a.

Slika 1. SD strukturni dijagram IS-a KS-a [9]

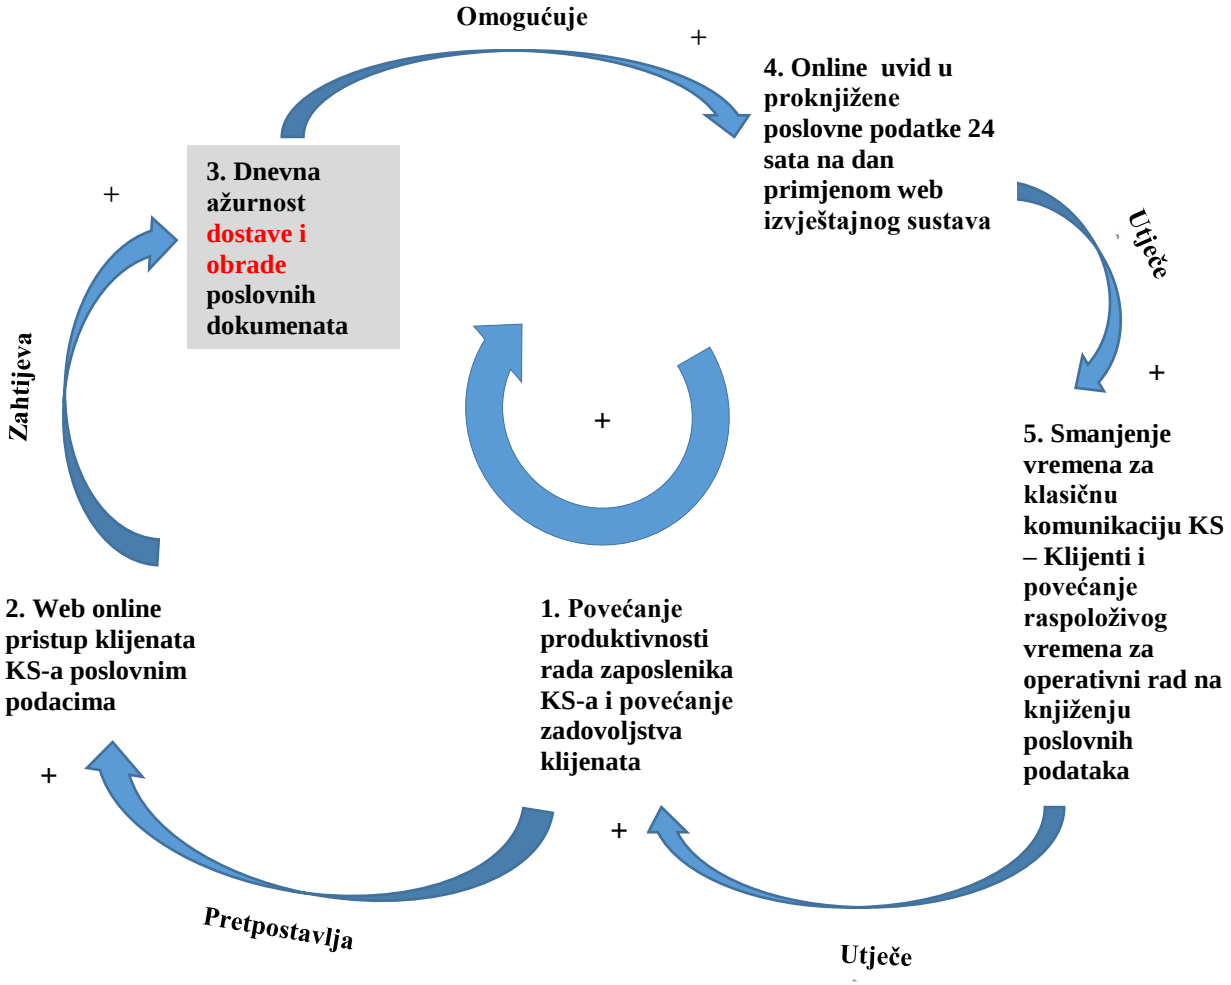

U izvoru [9] su, sukladno procesu broj 3. na slici 1., postavljena dva otvorena problemska pitanja, bez čijeg rješenja nije moguć daljnji značajniji napredak u unaprjeđenju i digitalnoj transformaciji IS-a KS-a, a to su pitanja:

- Kako postići ažurnost dostave poslovnih dokumenata na knjiženje u KS od strane klijenata ?
- Kako postići ažurnost obrade i knjiženja dostavljenih poslovnih dokumenata klijenata od strane zaposlenika KS-a ?

Odgovor na ova pitanja dale su nove tehnologije razmjene e-Računa između poslovnih subjekata, i tehnologije dohvata podataka o transakcijama na poslovnim računima (e-Izvodi banke), izravno iz ERP sustava poduzeća, a posredstvom novih metoda koje omogućuju Informacijski posrednici. Navedeno je jednako važno u svim tvrtkama, a posebno je naglašeno u knjigovodstvenim servisima koji pružaju knjigovodstvene usluge većem broju klijenata.

U ovom radu prezentirano je integrirano inovativno rješenje automatiziranog dohvata i obrade e-Računa i e-Izvoda banaka ugrađeno u paket ERP sustava FINKSQL [10], [11] u 2023. godini i implementirano u IS jednog od većih KS-a u RH, koje praktično omogućuje digitalnu transformaciju KS-a.

2. NOVI e-SERVISI INFORMACIJSKIH POSREDNIKA ZA DOHVAT e-RAČUNA I e-IZVODA BANAKA

Uloga Informacijskih posrednika definirana je Zakonom o elektroničkom računu u javnoj nabavi, NN 94/18, članak 3, stavak 4.: „Informacijski posrednik je pravna osoba koja, u skladu s europskom normom, pruža usluge zaprimanja i slanja elektroničkih računa i pratećih isprava, odnosno koja obavlja elektroničku razmjenu računa između izdavatelja eRačuna i primatelja, a koja može obavljati i usluge upravljanja cjelokupnim poslovnim procesom izdavanja, zaprimanja, slanja i arhiviranja eRačuna" [14].

Sukladno članku 3. stavak 3. ovog zakona „Financijska agencija (FINA) je centralni Informacijski posrednik koji obavlja uslugu zaprimanja i slanja elektroničkih računa i pratećih isprava čiji je djelokrug definiran posebnim zakonom, odnosno obavlja elektroničku razmjenu računa između izdavatelja eRačuna i javnih naručitelja, u skladu s europskom normom, te na čiju su se centralnu platformu za razmjenu eRačuna dužni povezati ostali Informacijski posrednici…"

Popis Informacijskih posrednika u RH koji su povezani na centralnu platformu i usklađeni s normom za e-Račun dat je u tablici 1.

Kao što je vidljivo iz tablice 1., od 17 Informacijskih posrednika svega 7 podržava slanje i zaprimanje e-Računa, ali prema uputi Ministarstva gospodarstva, svi Informacijski posrednici koji nemaju potpunu uslugu, obavezni su čim prije uspostaviti cjelovitu uslugu zaprimanja i slanja e-Računa.

Tablica 1. Informacijski posrednici u RH [15]

R.br.	**Naziv**	**Funkcija**
1.	FINANCIJSKA AGENCIJA (FINA)	Slanje i zaprimanje e-Računa
2.	HRVATSKA POŠTA (HP)	Slanje i zaprimanje e-Računa
3.	Hrvatski telekom (HT	Slanje e-Računa
4.	mSTART d.o.o	Slanje e-Računa
5.	ELEKTRONIČKI RAČUNI d.o.o. (Moj-eRačun)	Slanje i zaprimanje e-Računa
6.	Megatrend Redok d.o.o. (OMNIZON)	Slanje e-Računa
7.	Hitra produkcija dokumenata d.o.o	Slanje i zaprimanje e-Računa
8.	EDITEL ADRIA d.o.o	Slanje i zaprimanje e-Računa
9.	POS d.o.o	Slanje e-Računa
10.	OPTIM IT d.o.o	Slanje e-Računa
11.	Raverus d.o.o.	Slanje e-Računa
12.	DB informatika d.o.o.	Slanje i zaprimanje e-Računa
13.	ExaByte d.o.o.	Slanje e-Računa
14.	V6 INFORMATIKA j.d.o.o	Slanje e-Računa
15.	PONDI d.o.o.	Slanje e-Računa

16.	IE Računi d.o.o.	Slanje e-Računa
17.	C LAB d.o.o.	Slanje i zaprimanje e-Računa

Iako je e-Račun u postupcima javne nabave u RH postao obvezan 1. srpnja 2019., temeljem čega je Vlada RH planirala postići proračunske uštede od oko 6% ukupnog iznosa nabave u RH, e-Račun još uvijek nije uveden kao obavezan i u svim tvrtkama izvan javne nabave.

Ta činjenica ne ide u korist tvrtkama koje su preuzele ulogu Informacijskih posrednika, a svakako bitno usporava digitalnu transformaciju gospodarstva. Sukladno navedenom neki Informacijski posrednici, pored usluge slanja i zaprimanja e-Računa [16], razvijaju i nude nove usluge, kao što je usluga e-Plati [17], pri čemu nude metode za slanje i dohvat e-Dokumenata koje se mogu integriratri u ERP sustav poduzeća. Sa stajališta IS-a KS-a, uz obaveznu razmjenu e-Računa, upravo je još to nedostajalo za mogućnost značajnije digitalne transformacije poslovnih procesa KS-a.

U nastavku ovog rada prezentirano je rješenje tvrtke INFOMIB d.o.o. (autor. S. Vidačić) u okviru paketa aplikacije FINKSQL [10], kojim se integriraju metode za dohvat e-Računa i e-Izvoda banaka koje nudi Informacijski posrednik ELEKTRONIČKI RAČUNI d.o.o. [16], [17].

3. INTEGRACIJA WEB METODA e-SERVISA Moj-eRačun I e-Plati U IS KS-a

Kao što je već naglašeno u uvodnom dijelu ovog rada, u okviru IT usluga Informacijskih posrednika razvijene su web metode koje ugovornim korisnicima tih usluga omogućuju slanje i preuzimanje e-Računa u digitalnom obliku, preuzimanje e-Bankovnih izvadaka s podacima o transakcijama na poslovnim računima banaka i druge usluge.

U ovom radu prezentirana je odgovarajuća IT podrška u okviru ERP sustava KS-a (paket aplikacije FINKSQL [10]) koja omogućuje automatsko pokretanje predmetnih web metoda i dohvat digitalnog sadržaja e-Dokumenata svih klijenata KS-a u bazu podataka KS-a u vanradno vrijeme, bez ikakve aktivnosti operatera u KS-u.

Temeljni preduvjet informatičke podrške Informacijskog posrednika Moj-eRačun, važan za razvoj programske podrške u okviru ERP-a KS-a za integraciju web metoda e-Servisa sa ERP sustavom KS-a je postojanje funkcionalne Demo okoline za razvoj i testiranje programske podrške na strani ERP-a, slično kao i u slučaju uvođenja fiskalizacije,

3.1. UPRAVLJANJE PROCESOM DOHVATA E-DOKUMENATA

Za upravljanje procesom dohvata e-Dokumenata sa poslužitelja (servera) Informacijskog posrednika, u konfiguracijsku datoteku aplikacije FINKSQL ugrađen je set novih upravljačkih varijabli opisan u tablici 2.

Tablica 2. Upravljačke varijable procesa dohvata e-Dokumenata

Upravljačka varijabla	**Vrijednost – Link**
eRacun_Demo_Prod	.F. – demo, .T. – produkcija
	Demo okolina - eRačun
eRacun_Demo_Ser_Inb	https://demo.moj-eracun.hr/apis/v2/queryInbox
eRacun_Demo_Ser_Out	https://demo.moj-eracun.hr/apis/v2/queryOutbox
eRacun_Demo_Ser_Rec	https://demo.moj-eracun.hr/apis/v2/Receive
	Produkcijska okolina - eRačun
eRacun_Prod_Ser_Inb	https://www.moj-eracun.hr/apis/v2/queryInbox
eRacun_Prod_Ser_Out	https://www.moj-eracun.hr/apis/v2/queryOutbox
eRacun_Prod_Ser_Rec	https://www.moj-eracun.hr/apis/v2/Receive
	Demo okolina - ePlati
ePlati_Demo_Server	https://testapi.e-plati.hr/api/v1/getBankStatements
	Produkcijska okolina - ePlati
ePlati_Prod_Server	https://appapi.e-plati.hr/api/v1/getBankStatements
	Uključenost pojedinih procedura za dohvat podataka
Start_ePlati_Izvodi	.T. = da, .F. = ne
Start_eRacuni_Ura	.T. = da, .F. = ne
Start_eRacuni_Ira	.T. = da, .F. = ne
	Pristupni podaci za e-Račune (produkcija): servis - eMoj-Racun
eRacun_UserName	******
eRacun_Password	******
eRacun_SoftwareId	eFinkSQL-001
	Pristupni podaci za e-Izvadke banaka (produkcija): servis - ePlati
ePlati_UserName	******
ePlati_Password	******
ePlati_SoftwareId	eFinkSQL-001
	Vrijeme starta procedura za dohvat podataka
StartGetEplati_Time	06:30:00

U paket aplikacije FINKSQL, za upravljanje procesom dohvata e-Dokumenata, ugrađena je posebna serverska aplikacija FINK_BANK_IZV [11] čije su funkcije:

- Automatsko pokretanje na serveru KS-a u planski zadano vanradno vrijeme,
- Uspostava komunikacije sa serverom Informacijskog posrednika.,
- Dohvat e-Izvoda banaka i e-Računa klijenata KS-a i zapis njihovog sadržaja u SQL bazu aplikacije FINKSQL u TXT, XML i PDF formatima u dbo tablice:
    - dbo.Firme_Banke_eIzvodi (Formati: TXT, XML, PDF)

- dbo.Firme_eRacuni_Ira (Formati: XML, PDF)
- dbo.Firme_eRacuni_Ura (Formati: XML, PDF)

Dohvat e-Dokumenata je serijski proces koji se realizira uzastopnim pokretanjem tri procedure jednom u 24 sata u zadano vrijeme:

1.) Procedura: **Get_Banke_eIzvadci()**
2.) Procedura: **Get_eRacuni_Ura_IRA(„URA“)**
3.) Procedura: **Get_eRacuni_Ura_Ira(„IRA“)**

Proces dohvata e-Dokumenata pomoću navedenih procedura detaljnije je opisan u nastavku ovog rada.

3.2. TABLICE U SQL BAZI APLIKACIJE FINKSQL KAO OSNOVA DIGITALNE ARHIVE E-DOKUMENATA

U SQL bazu aplikacije FINKSQL dodane su tri nove SQL tablice:

- **dbo.Firme_Banke_eIzvodi:** Tablica je namijenjena za zapis podataka o preuzetim e-Izvodima banaka klijenata KS-a (Tablica 3.);
- **dbo.Firme_eRacuni_Ira:** Tablica je namijenjena za zapis podataka o preuzetim izlaznim e-Računima klijenata KS-a (Tablica 4.);
- **dbo.Firme_eRacuni_Ura:** Tablica je namijenjena za zapis podataka o preuzetim ulaznim e-Računima klijenata KS-a (Tablica 5.).

Tablica 3. Struktura SQL tablice **dbo.Firme_Banke_eIzvodi**

Naziv polja	**Format polja**	**Opis polja**
Firme_FirMatBroj	char (13)	MB klijenta
Firme_Naziv	varchar(64)	Naziv klijenta
Iban	char(21)	IBAN klijenta
Godina	char](4)	Godina
Broj_Izv	char(3)	Broj izvadka
Valuta	char](3)	Vrsta valute
Tip	char(3)	Tip podataka izvoda (TXT/XML/PDF
TxtMemo	varchar(max)	Izvadak u TXT – fina formatu
PdfMemo	varchar(max)	Izvadak u PDF formatu
XmlMemo	varchar(max)	Izvadak u XML formatu
Link_Izv	varchar(120)	Link s kojeg je e-Izvadak preuzet
DatumImporta	datetime	Datum i vrijeme preuzimanja e-Izvadka
BrojTem	char(12)	Broj temeljnice u koju je e-Izvadak proknjižen
DatumTem	datetime	Datum na koji je e-Izvadak proknjižen u temeljnicu

Polja u strukturi SQL tablice **dbo.Firme_Banke_eIzvodi:** TxtMemo, XmlMemo i PdfMemo su ključna za memoriranje sadržaja e-Izvadaka banke u izvornom digitalnom obliku i formiranje digitalne arhive izravno dostupne iz aplikacije FINKSQL za vizualizaciju dokumenata u pdf formatu i daljnju obradu podataka iz e-Izvoda banaka u TXT ili XML formatu.

Tablica 4. Struktura SQL tablice **dbo.Firme_eRacuni_Ira**

Naziv polja	**Format polja**	**Opis polja**
Firme_FirMatBroj	char(13)	MB klijenta KS-KS
Godina	char(4)	Godina
PoslovniPartner_Oib	char(11)	OIB kupca
ElectronicId	char(10)	Elektronički ID e-Računa
DocumentNr	char(20)	Fiskalni broj e_Računa
DvoRacuna	datetime	Datum e-Računa
Valutaracuna	datetime	Valuta e-Računa
Sent	datetime	Datum slanja e-Računa
StatusId	char(2)	Status e-Računa: 40 - preuzeto 30 – poslano
Valuta	char(3)	Vrsta valute
VrstaRacuna	char(3)	FAK-račun, TER-terećenje, ODO - odobrenje
XmlMemo	varchar(max)	Sadržaj e-Računa u xml-u
PdfMemo	varchar(max)	Sadržaj e-Računa u pdf-u
DatumImporta	datetime	Datum preuzimanja
Naziv	varchar(100)	Naziv kupca
Ulica	varchar(35)	Ulica i broj
Mjesto	varchar(35)	Naziv mjesta
BrojPoste	char(5)	Broj pošte
Drzava	char(3)	Država
IznosRobe	decimal(15, 2)	Vrijednost robe
IznosRabata	decimal(15, 2)	Iznos zabata
IznosOsnovice	decimal(15, 2)	Ukupna osnovica
IznosPdv	decimal(15, 2)	Ukupni iznos pdv-a
IznosUkupno	decimal(15, 2)	Ukupni iznos
Stopa pdv1	decimal(5, 2)	Stopa pdv1 (%)
Osnovica pdv1	decimal(15, 2)	Osnovica pdv1
Iznos pdv1	decimal(15, 2)	Iznos pdv1

StopaPdv2	decimal(5, 2)	Stopa pdv2 (%)
OsnovicaPdv2	decimal(15, 2)	Osnovica pdv2
IznosPdv2	decimal(15, 2)	Iznos pdv2
StopaPdv3	decimal(5, 2)	Stopa pdv3 (%)
OsnovicaPdv3	decimal(15, 2)	Osnovica pdv3
IznosPdv3	decimal(15, 2)	Iznos pdv3
BrojIra	char(12)	Broj u KIRA
DatumKnjiz	datetime	Datum knjiženja u knjigu KIRA

Tablica 5. Struktura SQL tablice **dbo.Firme_eRacuni_Ura**

Naziv polja	**Format polja**	**Opis polja**
Firme_FirMatBroj	char(13)	MB klijenta KS-KS
Godina	char(4)	Godina
PoslovniPartner_Oib	char(11)	OIB dobavljača
ElectronicId	char(10)	Elektronički ID e-Računa
DocumentNr	char(20)	Fiskalni broj e-Računa
DvoRacuna	datetime	Datum e-Računa
ValutaRacuna	datetime	Valuta e-Računa
Sent	datetime	Datum slanja e-Računa
StatusId	char(2)	Status e-Računa: 40 - preuzeto 30 – poslano
Valuta	char(3)	Vrsta valute
VrstaRacuna	char(3)	FAK-račun, TER-terećenje, ODO - odobrenje
XmlMemo	varchar(max)	Sadržaj e-Računa u xml-u
PdfMemo	varchar(max)	Sadržaj e-Računa u pdf-u
DatumImporta	datetime	Datum preuzimanja
Naziv	varchar(100)	Naziv dobavljača
Ulica	varchar(35)	Ulica i broj
Mjesto	varchar(35)	Naziv mjesta
BrojPoste	char(5)	Broj pošte
Drzava	char(3)	Država
IznosRobe	decimal(15, 2)	Vrijednost robe
IznosRabata	decimal(15, 2)	Iznos zabata
IznosOsnovice	decimal(15, 2)	Ukupna osnovica

IznosPdv	decimal(15, 2)	Ukupni iznos pdv-a
IznosUkupno	decimal(15, 2)	Ukupni iznos
Stopa pdv1	decimal(5, 2)	Stopa pdv1 (%)
Osnovica pdv1	decimal(15, 2)	Osnovica pdv1
Iznos pdv1	decimal(15, 2)	Iznos pdv1
StopaPdv2	decimal(5, 2)	Stopa pdv2 (%)
OsnovicaPdv2	decimal(15, 2)	Osnovica pdv2
IznosPdv2	decimal(15, 2)	Iznos pdv2
StopaPdv3	decimal(5, 2)	Stopa pdv3 (%)
OsnovicaPdv3	decimal(15, 2)	Osnovica pdv3
IznosPdv3	decimal(15, 2)	Iznos pdv3
Potvrda	char(2)	DA – račun je odobren za knjiženje
DatumPotvrde	datetime	Datum odobrenja računa za knjiženje
BrojUra	char(12)	Broj u KURA
DatumKnjiz	datetime	Datum knjiženja u knjigu KURA

Polja u strukturi SQL tablica **dbo.Firme_eRacuni_Ira i dbo.Firme_eRacuni_Ura:** XmlMemo i PdfMemo su ključna za memoriranje sadržaja ulaznih i izlaznih e-Računa u izvornom digitalnom obliku i formiranje digitalne arhive izravno dostupne iz aplikacije FINKSQL za vizualizaciju dokumenata u pdf formatu i daljnju obradu podataka iz e-Računa u XML formatu.

Polja u strukturi SQL tablica **dbo.Firme_eRacuni_Ira i dbo.Firme_eRacuni_Ura:** IznosRobe, IznosRabata, IznosOsnovice, IznosPdv, IznosUkupno, Stopa pdv1, Osnovica pdv1, Iznos pdv1, StopaPdv2, OsnovicaPdv2, IznosPdv2, StopaPdv3, OsnovicaPdv3, IznosPdv3 sadrže kumulativne podatke dekodirane iz XML sadržaja e-Računa koji se knjiže u poreznu evidenciju (knjiga Ura, Knjiga Ira).

Pored svih ostalih podataka o U/I e-Računima iz tablica 4. i 5., navedeni podaci se dekodiraju i memoriraju u SQL bazu u procesu dohvata sadržaja e-Računa, čime se realizira prva faza preuzimanja podataka iz e-Računa u poreznu evidenciju, koja omogućuje predkontrolu podataka od strane operatera KS-a, prije konačne obrade u okviru aplikacije FINKSQL.

3.3. PROCES DOHVATA, DEKODIRANJA I ARHIVIRANJA E-IZVODA BANAKA U SQL BAZU KS-A

Kompletan proces izvodi procedura **Get_Banke_eIzvadci()** u okviru serverske aplikacije FINKSQL_BANK_IZV [11].

Algoritam procesa ima sljedeće korake:

1.) Korak
Automatsko kreiranje zahtjeva za dohvat podataka sa servera Informacijskog posrednika u JSON formatu (Slika 2.).

Slika 2. Zahtjev za dohvat e-Izvoda banaka (Zahtjev_eIzvadak.json)

```
{
"username": "Korisničko ime",
"password": "Lozinka",
"companyid": "OIB",
"SoftwareId": "eFinkSQL-001",
"merDateFrom": "2023-08-10",
"merDateTo": "2023-08-10",
"consentStatus": 2
}
```

2.) Korak
Automatsko kreiranje BAT procedure **xMoj-Eracun_Izvod.bat** za slanje zahtjeva (request), pokretanje metode **getBankStatements** i preuzimanje odgovora (response) sa servera Informacijskog posrednika u JSON formatu (Slika 3.), primjenom aplikacije CURL [20].

Slika 3. Sadržaj cmd procedure **xMoj-Eracun_Izvod.bat**

```
CURL -X POST -d @xZahtjev_eIzvadak.json https://appapi.e-plati.hr/api/v1/getBankStatements
HTTP/1.1 "Host: irpsd2.dynu.net:8040" -H "x-Request-ID: b78f8fd1-4bd9-a74f-4f8d-97842510f912" -H
"content-type:application/json; Content-Length: 244" --output xResponse_Banke_Link.json
```

3.) Korak
Automatsko pokretanje procedure **xMoj-Eracun_Izvod.bat** i preuzimanje odgovora u JSON formatu koji sadrži linkove za izravni dohvat (download) e-Izvoda banaka klijenata KS-a (Slika 4.).

Slika 4**.** JSON sadržaj koji vraća web metoda **getBankStatements** (Slika 3.)
xResponse_Banke_Link.json

[{"format":"**camt.053**","messageIdentification":"BCS2484008.20951181107.202308100001","creationDatetime":"2023-08-11T06:01:54.767","fromDate":"2023-08-10T00:00:00","toDate":"2023-08-10T00:00:00**","downloadLink":"https://appapi.e-plati.hr/api/v1/statements/ojsGpwAqQSR4VK0ye2FbFJLG5o1j6uPuxfabTRFq4fZKL7cDLLy_6TIMKjxyocwm"**,"vbdi":"2484008","bic":"RZBH HR 2X","bankName":"Raiffeisenbank Hrvatska","identification":"d6b02a0eb7ad4084a7d9fbbb6071864e","lglSequenceNumber":192,"filename":"\\\\elrpis.local\\dfs\\TppData\\Izvodi\\20951181107\\camt053\\2023\\8\\10\\BCS2484008.20951181107.202308100001.xml","accounts":[{"iban":"","currency":"EUR"}],"merChangeTime":"2023-08-11T06:01:54.767"},
{"format":"fina","messageIdentification":"BCS2484008.20951181107.202308100001","creationDatetime":"2023-08-11T06:01:54.767","fromDate":"2023-08-10T00:00:00","toDate":"2023-08-10T00:00:00","**downloadLink":"https://appapi.e-plati.hr/api/v1/statements/_tAXi_fST-Nn3M7QXhB25S5gyKYybAOHfLj_8KYco5WhMpGjMjWCPp4OJBPfq-Fg"**,"vbdi":"2484008","bic":"RZBH HR 2X","bankName":"Raiffeisenbank Hrvatska","identification":"d6b02a0eb7ad4084a7d9fbbb6071864e","lglSequenceNumber":192,"filename":"\\\\elrpis.local\\dfs\\TppData\\Izvodi\\20951181107\\fina\\2023\\8\\10\\BCS2484008.20951181107.202308100001.txt","accounts":[{"iban":"","currency":"EUR"}],"merChangeTime":"2023-08-11T06:01:54.767"},
{"format":"pdf","messageIdentification":"BCS2484008.20951181107.202308100001","creationDatetime":"2023-08-11T06:01:54.767","fromDate":"2023-08-10T00:00:00","toDate":"2023-08-10T00:00:00","**downloadLink":"https://appapi.e-plati.hr/api/v1/statements/fDfrLK42DRygc6RIydTxZKQbYHaotNWiBTG32fY9X99kGiNNj1cLOdZxMVeLZYKK"**,"vbdi":"2484008","bic":"RZBH HR 2X","bankName":"Raiffeisenbank Hrvatska","identification":"d6b02a0eb7ad4084a7d9fbbb6071864e","lglSequenceNumber":192,"filename":"\\\\elrpis.local\\dfs\\TppData\\Izvodi\\20951181107\\pdf\\2023\\8\\10\\BCS2484008.20951181107.202308100001.pdf","accounts":[{"iban":"","currency":"EUR"}],"merChangeTime":"2023-08-11T06:01:54.767"}]

4.) Korak
Automatsko procesiranje preuzetog sadržaja iz **xResponse_Banke_Link.json** datoteke i automatsko pokretanje linkova i preuzimanje sadržaja e-Izvoda banaka **u XML**(camt.053), **TXT**(fina) i **PDF** formatu, te arhiviranje digitalnih podataka e-Izvoda banaka u SQL tablicu **dbo.Firme_Banke_eIzvodi** u varchar(max) poljima **TxtMemo**, **XmlMemo** i **PdfMemo**, za daljnju obradu u okviru aplikacije FINKSQL.

3.4. PROCES DOHVATA, DEKODIRANJA I ARHIVIRANJA E-RAČUNA U SQL BAZU KS-A

Kompletan proces izvodi procedura **Get_eRacuni_Ura_IRA()** u okviru serverske aplikacije FINKSQL_BANK_IZV [11]. Ako je procedura pokrenuta s parametrom „URA“ preuzima i obrađuje podatke o ulaznim e-Računima klijenata KS-a, a ako je pokrenuta s parametrom „IRA“ preuzima i obrađuje podatke o izlaznim e-Računima klijenata KS-a.

Algoritam procesa ima sljedeće korake:

1.) Korak
Automatsko kreiranje zahtjeva za dohvat liste raspoloživih e-Računa sa servera Informacijskog posrednika u JSON formatu (Slika 5.).

Slika 5. Zahtjev za dohvat liste e-Računa (Zahtjev_eRacun1.json)

```
{
"username": "Korisničko ime",
"password": "Lozinka",
"companyid": "OIB",
"SoftwareId": "eFinkSQL-001",
"From": "2023-08-10",
"To": "2023-08-10”
}
```

2.) Korak
Automatsko kreiranje BAT procedure **xMoj-Eracun_Eracuni1.bat** za slanje zahtjeva (request), pokretanje metode **queryOutbox** (Izlazni računi) ili metode **queryInbox** (ulazni računi) i preuzimanje odgovora (response) sa servera Informacijskog posrednika u JSON formatu (Slika 6.), primjenom aplikacije CURL [20].

Slika 6. Sadržaj cmd procedure **xMoj-Eracun_Eracuni1.bat**

Izlazni računi:
CURL -X POST -d @xZahtjev_eRacun1.json https://www.moj-eracun.hr/apis/v2/**queryOutbox** -H "content-type:application/json; charset:utf-8" --output **xResponse_eIra_Link1.json**

Ulazni računi:
CURL -X POST -d @xZahtjev_eRacun1.json https://www.moj-eracun.hr/apis/v2/**queryInbox** -H "content-type:application/json; charset:utf-8" --output **xResponse_eUra_Link1.json**

3.) Korak
Automatsko pokretanje procedure **xMoj-Eracun_Eracuni1.bat** i preuzimanje odgovora u JSON formatu (**xResponse_eIra_Link1.json, xResponse_eUra_Link1.json)** koji sadrži **ElectronicId** e-Računa klijenata KS-a raspoloživih za izravni dohvat (download) (Slika 7.).

Slika 7**.** JSON sadržaj koji vraćaju web metode **queryOutbox** i **queryInbox** (Slika 6.)

[{"**ElectronicId**":57898797,"DocumentNr":"1498-01-91","DocumentTypeId":1,"DocumentTypeName":"eInvoice","StatusId":40,"StatusName":"Delivered","RecipientBusinessNumber":"66498917936","RecipientBusinessUnit":"","RecipientBusinessName":"","Created":"2023-08-04T10:29:02.09","Updated":"2023-08-07T11:52:48.463","Sent":"2023-08-04T10:32:33.403","Delivered":"2023-08-07T11:52:48.463"},
{"**ElectronicId**":57929710,"DocumentNr":"1499-01-91","DocumentTypeId":1,"DocumentTypeName":"eInvoice","StatusId":40,"StatusName":"Delivered","RecipientBusinessNumber":"81499488050","RecipientBusinessUnit":"","RecipientBusinessName":"","Created":"2023-08-04T15:08:57.043","Updated":"2023-08-07T19:09:16.213","Sent":"2023-08-04T15:12:17.233","Delivered":"2023-08-04T15:12:19.863"},
{"**ElectronicId**":58076948,"DocumentNr":"1506-01-91","DocumentTypeId":1,"DocumentTypeName":"eInvoice","StatusId":40,"StatusName":"Delivered","RecipientBusinessNumber":"59035887147","RecipientBusinessUnit":"","RecipientBusinessName":"","Created":"2023-08-08T12:56:51.593","Updated":"2023-08-08T13:08:05.777","Sent":"2023-08-08T13:02:18.747","Delivered":"2023-08-08T13:08:05.747"},
{"**ElectronicId**":58123990,"DocumentNr":"1507-01-91","DocumentTypeId":1,"DocumentTypeName":"eInvoice","StatusId":40,"StatusName":"Delivered","RecipientBusinessNumber":"04492664153","RecipientBusinessUnit":"","RecipientBusinessName":"","Created":"2023-08-09T11:20:17.407","Updated":"2023-08-09T11:40:13.23","Sent":"2023-08-09T11:22:21.737","Delivered":"2023-08-09T11:40:13.23"}]

4.) Korak
Automatsko kreiranje zahtjeva za dohvat sadržaja pojedinog e-Računa u XML formatu sa liste raspoloživih e-Računa (Slika 7.), na temelju ključa **ElectronicId** (Slika 8.).

Slika 8. Zahtjev za dohvat e-Računa (Zahtjev_eRacun2.json)

{
"username": "Korisničko ime",
"password": "Lozinka",
"companyid": "OIB",
"SoftwareId": "eFinkSQL-001",
"ElectronicId": "57898797"
}

5.) Korak
Automatsko kreiranje BAT procedure **xMoj-Eracun_Eracuni2.bat** za slanje zahtjeva (request), pokretanje metode **Receive** (ulazni i izlazni računi) i preuzimanje e-Računa (response) sa servera Informacijskog posrednika u XML formatu (Slika 9.), primjenom aplikacije CURL [20].

Slika 9. Sadržaj cmd procedure **xMoj-Eracun_Eracuni2.bat**

Izlazni računi:
CURL -X POST -d @xZahtjev_eRacun2.json https://www.moj-eracun.hr/apis/v2/**Receive** -H "content-type:application/json; charset:utf-8" --output **xResponse_eIra_Link2.xml**

Ulazni računi:
CURL -X POST -d @xZahtjev_eRacun2.json https://www.moj-eracun.hr/apis/v2/**Receive** -H "content-type:application/json; charset:utf-8" --output **xResponse_eUra_Link2.xml**

6.) Korak
Automatsko pokretanje procedure **xMoj-Eracun_Eracuni2.bat** i preuzimanje odgovora (e-Račun) u XML formatu (**xResponse_eIra_Link2.xml, xResponse_eUra_Link2.xml)** za zadani **ElectronicId,** te arhiviranje digitalnih podataka e-Računa u SQL tablice **dbo.Firme_eRacuni_Ura** (ulazni računi) ili **dbo.Firme_eRacuni_Ira** (izlazni računi) u varchar(max) poljima **XmlMemo** i **PdfMemo**, za daljnju obradu u okviru aplikacije FINKSQL.

Pored općih, analitičkih i sintetičkih podataka sadržanih u XML strukturi e-Računa (točka 3.2.), u XML strukturu je integriran i PDF sadržaj orginalnog računa u base64 formatu, koji se automatski izdvaja iz XML sadržaja i memorira u polje PdfMemo navedenih SQL tablica. Time je osigurana digitalna arhiva i vizualizacija računa u izvornom obliku.

4. DIGITALNA ARHIVA DOKUMENATA KLIJENATA KS-a

U okviru IS-a KS-a osnovni masovni objekti obrade su poslovni dokumenti koje izrađuju klijenti KS-a u okviru svojih ERP sustava (Izlazni računi) ili njihovi dobavljači (Ulazni računi) ili poslovne banke (Bankovni izvadci).

Budući da KS vodi financijsko knjigovodstvo svojih klijenata koje se temelji na knjiženju podataka sa izvornih financijskih dokumenata, isti moraju biti fizički dostupni operateru koji knjiži, te odloženi u arhivu u okviru KS-a kao originalna podloga za knjiženje.

Klasična arhiva dokumenata u papirnatom obliku odavno je postala balast ureda svih tvrtki pa tako i KS-a i odavno se traže načini za uvođenje digitalne arhive [18], [19].

U klasičnim tvrtkama temeljna digitalna arhiva podataka od kojih su formirani dokumenti je baza podataka, iz koje se u okviru ERP sustava izlazni dokumenti(npr. Izlazni računi) koje generira ERP poduzeća bilo kada mogu vizualizirati na papiru ili nekom drugom formatu, ali u obliku elektroničke datoteke (TXT, PDF, XML i sl.).

Međutim, uvijek ostaje problem arhive ulaznih dokumenata (npr. Ulazni računi, Bankovni izvadci i sl.), koji u poduzeće dolaze poštom – na papiru, mailom – u obliku datoteke u nekom formatu ili kroz sustav e-Računa u obliku datoteke u XML formatu i sl.

Klasična digitalna arhiva U/I dokumenata koja se temelji na datotekama u različitim formatima u poslovnom IS-u iz mnogih razloga nije praktična. Taj problem je posebno izražen u IS-u KS-a čiji posao nije da generiraju dokumente koji se obrađuju, već obrađuju - knjiže dokumente

koje su generirali njihovi klijenti u okviru svojih ERP sustava, a zatim iste dostavljaju KS-u na knjiženje.

U ovom radu prezentiran je novi oblik digitalne arhive dokumenata klijenata KS-a koja ima sljedeće značajke:

- Nema arhive U/I dokumenata u papirnatom obliku,
- Nema arhive U/I dokumenata u obliku datoteka,
- Izvorni 'source code' sadržaja kompletnog dokumenta spremljen je u bazu podataka u formatima (TXT, XML, PDF) odakle se može vizualizirati prema potrebi,
- Digitalna arhiva dokumenata nastaje u automatiziranom procesu i ne zahtijeva posebno administriranje.

Na slici 10. novi oblik digitalne arhive (DARH) KS-a označen je kao arhiva 3. generacije.

Slika 10. Digitalna arhiva dokumenata KS-a 3. generacije

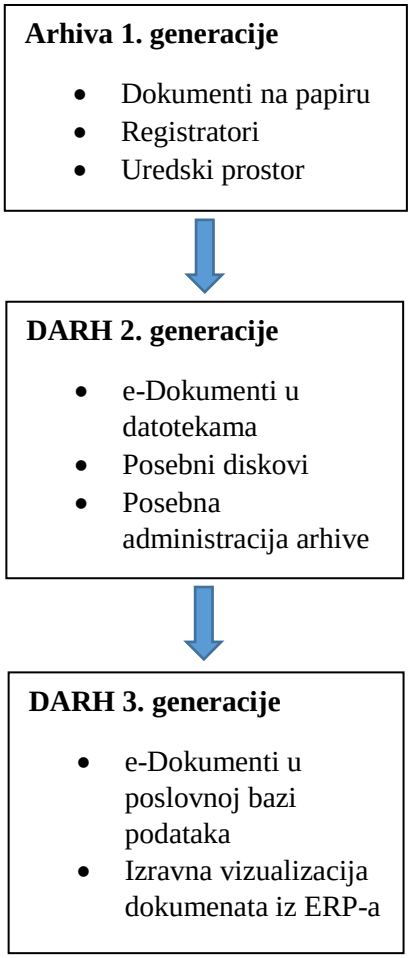

5. DIGITALNA TRANSFORMACIJA IS-a KS-a

Značajke prethodnog stanja IS-a KS-a, prije implementacije novog rješenja prezentiranog u ovom radu bile su:

- Rad s orginalnim dokumentima na papiru (URA, IRA),

- Dostava orginalnih dokumenata od strane klijenata i / ili dostava sintetičkih podataka u XLS formatu,
- Pojedinačno preuzimanje e-Izvadaka sa web portala poslovnih banaka,
- Licenciranje operatera u KS-u za preuzimanje e-Izvadaka i primjena tokena,
- Kontinuirani problemi u komunikaciji s klijentima od strane djelatnika KS-a,
- Kašnjenje u obradi podataka i neažurnost knjigovodstva u realnom vremenu,
- Arhiva proknjiženih dokumenata klijenata u papirnatom obliku.

Očekivane značajke budućeg stanja IS-a KS-a koje pretstavljaju digitalnu transformaciju, nakon implementacije novog rješenja prezentiranog u ovom radu su:

- Automatsko preuzimanje e-Izvadaka, e-Ura, e-Ira i automatsko ažuriranje baze podataka (digitalna arhiva) KS-a u noćnim satima za prethodni dan,
- Minimalizirana klasična obrada računa URA/IRA koji nisu izdani kroz sustav e-Računa i spremanje istih u pdf formatu u digitalnu arhivu u bazi podataka,
- Ažurnost automatske dostave i obrade dokumenata klijenata u realnom vremenu – idući dan nakon izdavanja - primanja, bez kašnjenja,
- Komunikacija djelatnika KS-a i klijenata svedena je na minimum,
- Fokusiranost djelatnika KS-a gotovo isključivo na automatiziranu kontrolu, vizualizaciju i knjiženje sadržaja dokumenata koji su automatski spremljeni u bazu podataka,
- Formirana operativna i trajna digitalna arhiva dokumenata u bazi podataka koja isključuje potrebu za razmjenom datoteka i klasičnim arhiviranjem dokumenata u papirnatom obliku,
- Mogućnost online rada djelatnika servisa na knjiženju jer su dokumenti koji su podloga za knjiženje izravno dostupni kroz bazu podataka,
- Značajno povećanje produktivnosti rada u okviru IS-a KS-a itd.

Za ostvarenje prethodno navedenih očekivanih značajki i digitalne transformacije poslovnih procesa KS-a, sa stajališta IT podrške ostvareni su svi potrebni preduvjeti (informacijski posrednici, web metode sustava e-Računa, web metode sustava e-Plati i mogućnost integracije s aplikacijama ERP sustava KS-a), ali realizacija ovisi o potpunoj uspostavi sustava e-Računa u kompletnom gospodarstvu RH.

6. ZAKLJUČAK

U ovom radu prezentirana je programska podrška na kojoj se temelji integracija novih web metoda sustava e-Računa i e-Plati za online dohvat i automatsku obradu e-Računa i e-Izvoda banaka u okviru aplikacija ERP sustava knjigovodstvenih servisa (KS).

Nove web metode u kontekstu razmjene e-Računa i dohvata podataka o transakcijama na poslovnim računima banaka razvili su Informacijski posrednici u RH i iste nude kao nove web usluge. Upravo je najnovija web usluga e-Plati bila poticaj za izradu i stavljanje u produkciju programskog rješenja prezentiranog u ovom radu, jer je prepoznata kao mogućnost podizanja razine digitalne transformacije poslovnih procesa jednog od većih KS-a u RH.

Nove web metode koje razvijaju Informacijski posrednici jesu nova standardizirana IT mogućnost koja jače pozicionira ulogu tih tvrtki u sustavu e-Poslovanja, međutim primjena tih

metoda u praksi zahtijeva njihovu integraciju u programska rješenja ERP sustava poslovnih subjekata, za što ne postoje standardizirana rješenja.

Programsko rješenje navedene integracije prezentirano u ovom radu u praktičnoj primjeni pokazuje se kao vrlo efikasno i može poslužiti kao jedan od mogućih modela rješenja.

Integracija sustava razmjene e-Računa između kupaca i dobavljača, te između Informacijskih posrednika je relativno jednostavna, međutim integracija usluge e-Plati je složenija, zato što je potrebno provođenje određenog administrativnog postupka kojim poslovni subjekti daju privolu za pristup servisa Informacijskog posrednika njihovim transakcijama u poslovnim bankama, te zato što je potrebna vremenska sinkronizacija pripreme i preuzimanja podataka između IS-a banaka, Informacijskog posrednika i KS-a.

Ono što se sa stajališta autora može smatrati inovativnim rješenjem prezentiranim u ovom radu je tehnologija i način na koji se izvorni dokumenti (e-Računi i e-Izvodi banke) u digitalnom obliku memoriraju u bazu podataka kao novi oblik digitalne arhive i time na novi efikasniji način postaju dostupni administratorima KS-a za dalju obradu, čime se bitno mijenjaju odnosi u komunikaciji između KS-a i njegovih klijenata.

Očekivani utjecaj u smislu digitalne transformacije koji takvo rješenje može imati na informacijske sustave velikih KS-a opisano je u točki 5.

U navedenom smislu masovna primjena usluge e-Plati i potpuna automatizacija dohvata i obrade izvoda banaka nije problem, ali masovna primjena sustava e-Računa ostaje problem sve dok e-Račun ne postane po zakonu obavezan za kompletno gospodarstvo.

REFERENCE

[1] Bala, Bilash Kanti, Arshad, Fatimah Mohamed, Noh, Kusairi Mohd: System dinamics, Modelling and Simulation, Springer, 2017, ISBN 978-981-10-2045-2.

[2] OMG (2011): "Business Process Model and Notation BPMN 2.0", http://www.bpmn.org, preuzeto: [30.07.2023].

[3] Vidačić, S., Dobrović, Ž: A New Standard of the Information Systems Used by Bookkeeping Services, Proceedings of the 17h International Conference of Information and Intelligent Systems - IIS'2006, september 20-22, Varaždin, 2006, str. 161-167.

[4] Vidačić, S., Dvorski, S.: A system for the Automatic Serial Generation and E-mailing of Business Letters, Proceedings of the 18h International Conference of Information and Intelligent Systems - IIS'2007, september 12-14, Varaždin, 2007, str. 171-176.

[5] Vidačić, S., Pihir, I., Brodar, K.: Model of Multi-criteria Ranking of Employees in Bookkeeping Agencies, Proceedings of the 20h International Conference of Information and Intelligent Systems - CECIIS'2009, september 23-25, Varaždin, 2009, str 211-218.

[6] Vidačić, S., Pihir, I.: Towards e-business in bookkeeping agencies: perceptions, problems and efficiency, Proceedings of the 26th International Conference of Information and Intelligent Systems - CECIIS'2015, september 23-25, Varaždin, 2015, pp. 135-141.

[7] Vidačić, S., Tomičić-Pupek, K., Pihir, I.: The orcestration of web-based sales processes a case study. Proceedings of the 11th International Scientific on Economic and Social Development – Bulding Resilient Society, Zagreb, Croatia, 17 – 18 december, 2015, pp. 336-341.

[8] Vidačić, S.: Web aplikacija za knjigovodstvene servise WebFINKSQL, Infomib d.o.o., Zagreb, (2016 – 2018).
[9] Vidačić, S.: *Model i efekti online web izvještajnog sustava knjigovodstvenog servisa*, Međunarodni znanstveno-stručni časopis CroDiM, Vol. 2, No. 1, 2019, UDC 658.8, e-ISSN 2584-7236, str. 197-206.
[10] Vidačić, S.: Programska aplikacija za knjigovodstvene servise FINKSQL, Infomib d.o.o., Zagreb, (2008 – 2023).
[11] Vidačić, S.: Programska aplikacija za knjigovodstvene servise FINKSQL_BANK_IZV, Infomib d.o.o., Zagreb, (2023).
[12] https://www.fluentis.com/hr/digital-transformation, preuzeto: [30.07.2023].
[13] https://apsolon.com/digitalna-transformacija-hrvatska-2020-hrvatski-digitalni-indeks/: preuzeto: [30.07.2023].
[14] https://www.zakon.hr/z/1163/Zakon-o-elektroni%C4%8Dkom-izdavanju-ra%C4%8Duna u-javnoj-nabavi, preuzeto: [30.07.2023].
[15] https://edukacije-appa.hr/novosti/poslovanje/novi-informacijski-posrednici-za-izdavanje-i-zaprimanje-eracuna, preuzeto: [03.08.2023].
[16] https://portal.moj-eracun.hr, preuzeto: [30.07.2023].
[17] https://e-plati.hr/eplati_1-23, preuzeto: [30.07.2023].
[18] https://www.tis.hr/hr/blog/kako-je-digitalna-arhiva-pobijedila-fizicku-arhivu, preuzeto: [02.08.2023].
[19] https://www.optimit.hr/e-arhiva, preuzeto: [02.08.2023].
[20] https://curl.se/docs/manpage.html#-d, preuzeto: [05.04.2023].

Professional paper / Stručni rad

MANIPULATIVNE PRIJETNJE UMJETNE INTELIGENCIJE

DAMIR DOBRINIĆ
Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
ddobrinic@foi.hr

SAŽETAK

U okviru ovog rada razmatra se uloga umjetne inteligencije kao čimbenika potencijalne manipulacije ponašanjem ljudi. Zlonamjerna manipulacija nije ništa novo i javlja se na svim stupnjevima ljudskog razvoja te je i kao takva predmet podučavanja za snalaženje u svakodnevnom životu. Brzi razvoj digitalnih tehnologija, a u posljednje vrijeme i tehnologija umjetne inteligencije dovodi i do razvoja različitih manipulativnih tehnika za koje ljudi nisu spremni i koje često ne mogu svjesno percipirati. Educiranost i poticanje digitalne i medijske pismenosti osnovni su mehanizmi obrane na osobnoj razini, dok se zaštita na široj razini uvodi kroz regulativu koja taj ubrzani digitalni razvoj nastoji i pratiti. U tom se smislu ističu dva bitna akta (zakona) Europske unije: Akt o digitalnim uslugama i Akt o umjetnoj inteligenciji. Akt o umjetnoj inteligenciji je pred usvajanjem i kao prvi takav akt regulira i područje korištenja umjetne inteligencije u manipulativne svrhe. Nakon pregleda osnovnih oblik korištenja umjetne inteligencije s potencijalnim manipulativnim učincima razmatraju se i mehanizmi zaštite od takvog utjecaja.

KLJUČNE RIJEČI: umjetna inteligencija, manipulativne tehnike, subliminalne tehnike, podsvjesna percepcija, EU regulativa,

1. UVOD

Nastojanje da određena komunikacija bude tajna ili da bude sakrivena od drugih javlja se već kod najranijih faza ljudskog razvoja. U skladu s društvenim i tehnološkim razvojem primjenjivale su se i različite tehnike prikrivanja poruka, od pisanja poruka na obrijanu glavu glasnika i voštanih pločica u staroj Grčkoj do nevidljive tinte, mikrofotografije, nulte šifre (poruka u poruci) i dr. Tehnika koja se često naziva i umjetnošću skrivanja informacija u nekom mediju (nositelju poruke ili informacije) naziva se steganografija. Za razliku od kriptografije gdje se određeni podaci kompletno transformiraju ili šifriraju kako bi bili nečitljivi, steganografija poruku sakriva u potpuno dostupan i vidljiv medij pa nitko, osim pošiljatelja i primatelja, ne može niti naslutiti da se u njemu nalazi sakrivena poruka. Može se reći kako steganografija skriva prisutnost poruke, odnosno poruka ne privlači pozornost na sebe [Quantamagazine, 2023].

Digitalno doba prati i steganografija koja se fokusira na digitalne oblike prikrivanja. Kao prijenosni medij koriste se digitalne fotografije, video i audio zapisi te se s obzirom na vrstu medija za skrivanje dijeli na steganografiju teksta i slike, audio i video steganografiju te mrežnu

steganografiju [Shih, 2017]. Najčešće se koristi steganografija slike gdje se poruka skriva unutar slike na način da se mijenjaju pikseli slike što ljudsko oko ne može zamijetiti. Kako bi se dodatno povećala sigurnost ova se tehnika može kombinirati i s kriptografijom. Steganografija svoju primjenu ima na raznim područjima i legalnim i ilegalnim. Najčešće se koristi kod kreiranja vodenog pečata u svrhu zaštite autorskih prava nad multimedijskim datotekama te kreiranja digitalnog potpisa. Primjeri ilegalnog korištenja odnose se na područje sakrivanja dokaza o ilegalnim aktivnostima, krađu povjerljivih informacija financijske pronevjere, krađu identiteta, dječju pornografiju, terorizam i dr. [Carnet, 2023]. Koristi se i za širenje zlonamjernih programa koji se ugrađuju u slike koje se šalju elektroničkom poštom ili preuzimaju s interneta te kao takvi ostaju nevidljivi tradicionalnim sigurnosnim rješenjima. Klikom na sliku „oslobađa se“ zlonamjerni program koji inficira cijeli sustav.

U kontekstu sakrivanja poruka nužno je spomenuti i subliminalne tehnike koje su već duže vrijeme predmet proučavanja, naročito u psihologiji i marketingu gdje se žele iskoristiti za utjecaj na ponašanje kupaca. Taj se utjecaj manifestira kroz različite podražaje koji će primatelju (potencijalnom kupcu) biti nevidljivi, odnosno primit će ih na nesvjesnoj razini. Za odašiljanje i točno ciljanju tih podražaja, vremenu i intenzitetu danas sve više odlučuje umjetna inteligencija, što je i razlog da se na području Europske unije potakne rasprava o zakonskoj regulaciji tog područja. Niz je pozitivnih primjera korištenja subliminalnih tehnika uz pomoć umjetne inteligencije, međutim problem nastaje ukoliko će se te tehnike zlorabiti, Takve su pretpostavke dodatno ubrzale regulaciju primjene umjetne inteligencije u području korištenja subliminalnih tehnika, ali i šire [European Commission, 2021].

Kroz cjelokupnu ljudsku povijest javljali su se i određeni oblici štetne i zlonamjerne manipulacije ljudima i to nije ništa novo. Ljudi se kroz svoj rani odgoj i obrazovanje pripremaju za prepoznavanje i zaštitu od manipulacije, međutim nagli razvoj digitalnih tehnologija te tehnologija umjetne inteligencije donosi i oblike manipulacije za koje ljudi još nisu dovoljno pripremljeni. Future of Life Institute navodi nekoliko činjenica koje tome idu u prilog: [Future of Life Institute, 2022].

- nedostatak transparentnosti i objašnjivosti rada velike većine algoritama i manjak tehničke pismenost ljudi o nedostacima umjetne inteligencije
- umjetna inteligencija vrlo efikasno i precizno otkriva niz podataka koji određuju nekog pojedinca (preferencije, interesi, navike…) temeljem čega se sadržaj (oglasi) vrlo precizno personalizira
- mogućnost da se s velikom točnošću procjenjuje psihološko stanje pojedinaca (emocije, raspoloženje, stres…)
- slabljenje individualne autonomnosti svakog potrošača iskorištavanjem njegovu ranjivost u procesu donošenja odluke o kupnji.

Šteta koju manipulacije mogu izazvati nisu samo u sferi nagađanja one su stvarne što potvrđuje niz primjera. Tako je štetan utjecaj Instagramovog algoritma strojnog učenja potvrdio i sam Facebook koji je u periodu od 2019. do 2021. godine provodio svoje interno istraživanje (koje je dospjelo u javnost) utjecaja aplikacija za dijeljenje slika na Instagramu na zdravlje mladih korisnika, prvenstveno tinejdžerica. Utvrđeno je da kod jedne od tri tinejdžerice prikaz manipulativnih slika ljudi koji izgledaju savršeno i uživaju u životu uzrokuje probleme nezadovoljstva sa svojim tijelom. Pokazalo se kako je Instagram vrlo toksično okruženje za tinejdžerice koje uzrokuje probleme nezadovoljstva sa svojim tijelom, anksioznost pa čak i suicidne misli [The Wall Street Journal, 2021].

Drugi se primjer odnosi na skandal kojeg je 2014. godine prouzročila američka konzultantska tvrtka specijalizirana za politička savjetovanja Cambridge Analytica. Tvrtka je uspjela na prijevaru (lažno navodeći svrhu) od Facebooka dobiti podatke o preko 50 milijuna korisnika mreže bez njihove dozvole. Podaci su prikupljeni putem kviza na Facebooku koji je pozivao korisnike da saznaju svoj tip osobnosti. Aplikacija je bila osmišljena na način da su se prikupljali korisnički podaci sudionika kviza, ali i njihovih prijatelja. Korištenjem analitike velikih podataka kreirali su se psihografski profili američkih glasaća kako bi se precizno ciljali političkim porukama [Lenca 2018]. Online podaci iskorišteni su za algoritamsko predviđanje i utjecaj na ljudsko ponašanje. Radi se o najvećem zabilježenom „curenju" podataka na Facebooku.

U preambuli Ustava Organizacije Ujedinjenih naroda za obrazovanje, znanost i kulturu – UNESCO (engl. *United National Educational, Scientific and Cultural Organization*) stoji rečenica: *„budući da ratovi počinju u umovima ljudi, u umovima ljudi mora biti izgrađena obrana mira"*. Ustav UNESCO-a donesen je njezinim osnivanjem 1945. godine, ali se ova misao može u potpunosti primijeniti i na današnje vrijeme naglog i, može se reći, nekontroliranog ili nedovoljno reguliranog razvoja i primjene umjetne inteligencije [Neuwirth, 2022).

2. UMJETNA INTELIGENCIJA I MANIPULATIVNE (SUBLIMINALNE) TEHNIKE

UNESCO, navodeći svoju ozbiljnu zabrinutost zbog mnogih etičkih pitanja koja su pokrenula inovacije na području razvoja i primjene umjetne inteligencije, poduzima prvi korak u pokušaju globalne regulacije ovog područja donoseći 2021. godine Preporuke o etici umjetne inteligencije, prvi međunarodni dokument za postavljanje standarda o umjetnoj inteligenciji koji prepoznaje „*duboke i dinamične pozitivne i negativne utjecaje umjetne inteligencije na društva, okoliš, ekosustave i ljudske živote uključujući ljudski um*" [UNESCO, 2023]. Preporuke su usvojene aklamacijom svih zemalja članica (njih 193). Prema riječima generalne direktorice UNESCO-a Audrey Azoulay, Preporuke pružaju alate koji će osigurati da se *„razvoj umjetne inteligencije pridržava zakona, izbjegavajući štetu i osiguravajući da kada je šteta učinjena, odgovornost i mehanizmi za obeštećenje budu dostupni onima koji su pogođeni*" [UNESCO, 2023a].

Trenutno je u fazi usuglašavanja donošenje i prvog sveobuhvatnog akta o reguliranju korištenja umjetne inteligencije na području Europske unije (Artificial Intelligence Act – EU AI Act). U sklopu njegovog prijedloga ističe se i problematika korištenja subliminalnih tehnika, odnosno predlaže se zabrana sustava umjetne inteligencije koji ih koriste. Tako članak 5. stavak 1a i 1b predloženog akta reguliraju područje korištenja umjetne inteligencije u manipulativne svrhe zabranjujući:

- (1a) „ *stavljanje na tržište, stavljanje u uporabu ili korištenje UI sustava u kojem se primjenjuju subliminalne tehnike zbog kojih osoba nesvjesno bitno mijenja svoje ponašanje na način koji toj ili drugoj osobi uzrokuje ili bi mogao prouzročiti tjelesnu ili psihološku štetu*",
- (1b) „*stavljanje na tržište, stavljanje u uporabu ili korištenje UI sustava koji iskorištava bilo koju slabost određene skupine osoba zbog njihove dobi ili tjelesnog ili mentalnog oštećenja radi bitnog mijenjanja ponašanja osobe koja pripada toj skupini na način koji toj ili drugoj osobi uzrokuje ili bi mogao uzrokovati tjelesnu ili psihološku štetu*". [CEU, 2022]

Stavak 1a Akta o umjetnoj inteligenciji pridržava se klasične definicije subliminalnih tehnika kao načina prezentiranja sadržaja na način da ga ciljana osoba ili osobe nisu svjesne, što je izazvalo i određene kritike stručne javnosti. Činjenica je kako značajan utjecaj subliminalnih poruka ili sadržaja na ponašanje ljudi (primatelja) nije utvrđen. U većini slučajeva stručnjaci se slažu da je utjecaj (ako postoji) puno manji od onoga kako se strahuje da ima. Meta analiza rezultata različitih istraživanja utvrdila je da tamo gdje se taj utjecaj utvrdio on nije bio statistički značajan [Franklin et al, 2022]. Nadalje, neka istraživanja koja su utvrdila utjecaj povezuju ga s namjerom, tj. primatelj poruke će kupiti proizvod ukoliko je već imao namjeru da ga kupi [Aarts et al., 2001]. Svemu tome može se dodati i različita percepcija subliminalnog sadržaja kod primatelja, neki će ga usvojiti na podsvjesnoj, a neki na svjesnoj razini.

Iako se u uvodnom dijelu Akta, obrazlažući motivaciju predlaganja zabrane u članku 5., pojašnjava kako se zabrana odnosi na „*sustave umjetne inteligencije koji koriste subliminalne komponente kao što su audio, slike, video podražaje koje osobe ne mogu percipirati jer su ti podražaji izvan ljudske percepcije ili druge subliminalne tehnike koje potkopavaju ili oštećuju autonomiju osobe, donošenje odluka ili slobodne izbore na načine kojih ljudi nisu svjesni ili čak i ako su svjesni ne mogu kontrolirati ili im se oduprijeti*“ [Aarts et al., 2001] smatra se kako to obrazloženje nije obvezujuće te će se stavak 1a različito tumačiti, prvenstveno u duhu klasičnih definicija subliminalnih tehnika. Iz tih se razloga predlaže zamjena termina subliminalne tehnike terminom manipulativne tehnike [Future of Life Institute, 2022].

Ljudi su svjesni mnogih aspekata svoje okoline, ali nisu nužno svjesni kako ti aspekti utječu na njihove misli i ponašanje [Franklin et al, 2022]. Može se konstatirati kako sva okruženja u određenoj mjeri utječu na ponašanje ljudi pa čak i kada ljudi toga nisu svjesni. Klasičan primjeri su generatori za preporuku sadržaja koji mijenjaju izbore koje korisnik može napraviti prilagođavajući rezultate pretraživanja na prvoj stranici tražilice ili predlaganje filmova za gledanje. Takvi utjecaji ne moraju biti nužno perceptivno subliminalni, ali su ipak sublimni u svom utjecaju. O promjeni aspekata okoline s ciljem utjecaja na ponašanje ljudi govori Thaler objašnjavajući značenje termina arhitektura izbora (engl. *choice architecture*) [Thaler, 2010]. Arhitektura izbora predstavlja dizajn različitih načina ili opcija za izbor te utjecaja na donošenje odluke ili kao što Thaler navodi „*promjena okruženja u kojem ljudi biraju kako bi donosili mudrije izbore bez ograničavanja ikakvih opcija*“. Na primjer, GPS aplikacija nudi moguće rute a korisnik odabire njemu najpovoljniju ili korisničko sučelje određene aplikacije koje nudi različiti izbor i utječe na donošenje odluke. Cilj je arhitekture izbora pomoći ljudima da dobrim izborom donesu bolje odluke i, ono što je bitno, prema njihovoj osobnoj procjeni.

Samo mijenjanje ili prilagođavanje arhitekture izbora s ciljem utjecaja na ponašanje ljudi bez ograničavanja ili forsiranja određenih opcija naziva se poticanje ili gurkanje (engl. *nuding*) [Thaler, 2010]. Može se definirati i kao „*sredstvo poticanja i navođenja na određeno ponašanje, ali bez elemenata obveznosti, kažnjavanja ili izravnog pokazivanja i financijskih nagrada*“ [CareerCentar, 2019]. U literaturi se često navodi primjer korištenja poticanja u odabiru zdravije hrane učenika u školskim kuhinjama [Metcalfe et al., 2020]. Digitalni razvoj i prenošenje tehnike poticanja u digitalno okruženje donosi i termin digitalni poticaji ili gurkanja (engl. *digital nudging*). Termin se odnosi na „*korištenje elemenata dizajna korisničkog sučelja za usmjeravanje ponašanja ljudi u okruženjima digitalnog izbora*“ [Schneider et al., 2018]. Primarni cilj poticanja je usmjeriti korisnika na izbor koji će njima biti zanimljiv, dok sekundarni cilj može biti da se usmjeravaju na one stavke koje sustav misli da će im biti zanimljive, a što može (i ne mora) dovesti i do određenih manipulacija [Jesse, Jannach, 2021]. Činjenica kako dizajneri sustava, temeljem promjena u dizajnu ili arhitekturi izbora, mogu

utjecati na ponašanje korisnika dovodi u pitanje funkcionalnost korisničkih preferencija [Ashton, Frenklin, 2022].

Ispravno i etičko korištenje poticaja, kao što naglašavaju Thaler i sur., treba krenuti od toga da se ljude usmjerava prema ostvarivanju njihovih vlastitih ciljeva, a ne da se ti ciljevi mijenjaju. Ljudi svakodnevno temeljem svojeg izbora donose odluke. Njihov izbor nije samo pod utjecajem racionalnog razmatranja postojećih opcija već i pod utjecajem dizajna okruženja izbora ili načina na koji im se informacije prezentiraju, što ima i određeni podsvjesni utjecaj [Weinmann et al, 2016]. To dovodi i do prakse korištenja digitalnih poticaja za stavljanje ciljeva tvrtke u prvi plan, odnosno onog tko ga provodi, zanemarivajući interese korisnika. Klasični je primjer cilj marketinških stručnjaka da prodaju što više proizvoda. Sustavi preporuka, koji se danas vrlo često koriste i sastavni su dio online poslovanja, trebali bi razviti algoritme koji će potencijalnim kupcima pomoći da pronađu ono što je za njih najrelevantnije. Ukoliko se određene opcije filtriraju, naročito kroz personalizaciju gdje sustav odlučuje što je za njih relevantno, autonomija i sloboda izbora će se narušiti [Jesse, Jannach, 2021].

Na taj oblik manipulacije ili promjene preferencija upozoravaju i Franklin i sur [Franklin et al, 2022]. Naime, sustavi preporuka vođeni strojnim učenjem „uče“ o ponašanju ljudi temeljem njihovih povijesnih ponašanja (podatak). Ti im podaci (zaključci) omogućavaju optimizaciju isporuke određenih usluga. Primjena tog iterativnog (ponavljajućeg) pristupa strojnog učenja (konstantnog ažuriranja parametara algoritma) na sustav preporuka postavlja se pitanje uči li sustav o preferencijama korisnika ili ih potiče na određeno ponašanje. Naime, algoritam temeljem povijesnih podataka predlaže popularne predmete (proizvode) što ih čini još popularnijima. S vremenom sustav sužuje opcije i sadržaj koji nudi čime narušava autonomiju i slobodu izbora korisnika.

U tom smislu Ience (2023) konstatira kako „*manipulaciju karakterizira nedostatak poštovanja prema autonomiji i slobodi djelovanja druge osobe i može se smatrati kršenjem njihovih osnovnih ljudskih prava*“ [Ience, 2023]. Nadalje, autor smatra kako se manipulacijom mogu kršiti kognitivne slobode jer se narušava pravo ljudi na samoodređenje. „*Kada se pojedincima manipulira, njihove misli, emocije i percepcije su (u različitoj mjeri) pod kontrolom ili utjecajem drugih, često bez njihova znanja ili pristanka*.“ [Ience, 2023] Nove tehnologije potencijalnu manipulaciju kojom se krši ljudska kognitivna sloboda i autonomija dodatno naglašavaju. Primjena velikih podataka (engl. *big data*) i umjetne inteligencije (strojnog učenja) potencijalno mogu utjecati na ljudsku sposobnost da kontroliraju svoju svijest i na taj način ugroziti njihov osjećaj autonomije i dostojanstva [Ienca, Malgieri, 2023]. Sve to otvara etička pitanja u vezi manipulacije koja može biti vođena ili posredovana novim tehnologijama, posebice primjenom umjetne inteligencije.

Naravno, ne može se generalno tvrditi da nove tehnologije narušavaju kognitivne slobode. U više navrata spomenuto je potencijalno narušavanje koje je, na žalost, već detektirano, međutim uvjeravanje koje se provodi na transparentan način u duhu definicije poticanja ili gurkanja može biti korisno i u skladu s kognitivnim slobodama, s obzirom da pomaže u donošenju kvalitetnijih odluka. U nastavku će se govoriti o netransparentnom utjecaju kojim se zaobilazi razum i kojim taj utjecaj ulazi u sferu manipulacije, koja prema Susser i sur. (2019) predstavlja skriveni utjecaj na nekoga na način da on toga nije svjestan ili na način kojeg on nije mogao lako postati svjestan [Susser et al., 2019].

U nastavku se navodi nekoliko primjera korištenja digitalne tehnologije (prvenstveno umjetne inteligencije) s potencijalnim manipulativnim učincima: [Bermudez et al., 2023] [Ience, 2023]

- **Društveni mediji**
  Društveni mediji predstavljaju web-bazirane aplikacije i interaktivne platforme koje omogućavaju kreiranje, raspravu, modifikacije i razmjenu sadržaja kojeg generiraju korisnici [Kaplan, Heanlein, 2010]. Zabrinutost u svezi potencijalnog manipulativnog djelovanja platformi društvenih medija proizlazi iz nekoliko aspekta njihovog rada: [Ience, 2023]
    - **Filtriranje sadržaja – tzv. filter mjehur** (engl. *filter bubbles*), moć algoritama je da prate online aktivnosti korisnika te temeljem povijesnog ponašanja nude sadržaj za koji oni smatraju da će korisniku biti zanimljiv i koristan. U bespuću informacija koje se nalaze na internetu prijedlog onoga što bi korisnika moglo zanimati zvuči dobro i svakako pomaže da se skrati vrijeme pretraživanja. Međutim, pojavljuje se problem određene izolacije korisnika od drugih njemu potencijalno zanimljivih informacija.
    - **Lažni računi i botov**i, većina mrežnih platformi omogućava otvaranje lažnih profila ili računa, odnosno računa koji nisu povezani sa stvarnim identitetom korisnika. Razlozi njihovog otvaranja mogu biti različiti, od satiričnih do prijevara i širenja lažnih vijesti. Takve račune mogu voditi i roboti ili straćeno botovi (inteligentni programski agenti/programi) upravljani umjetnom inteligencijom. Botovi mogu ostavljati oznake sviđanja (engl. *lajk*), komentirati, dijeliti sadržaj i sklapati prijateljstva kao i stvarni korisnici. Zahvaljujući procvatu umjetne inteligencije takve je lažne račune i teško prepoznati. Neka su istraživanja to i potvrdila, naime ispitanici nisu uspjeli razlikovati lažne od pravih računa, štoviše, ono što bi trebalo biti zabrinjavajuće, smatrali su da je veća vjerojatnost kako su pravi računi lažni [Anderere, 2023].
    - **Moderiranje sadržaja**, društvenim platforme koriste umjetnu inteligenciju za pregledavanje, prepoznavanje i uklanjanje štetnog ili neprimjerenog sadržaja. Pored neupitne koristi toga postoji i potencijalna opasnost manipulacije u smislu filtriranja i cenzuriranja koje narušava prava i slobode korisnika. Europska unija tu problematiku unosi i u Akt o digitalnih uslugama koji je stupio na snagu 16. studenog 2022. godine navodeći pravila moderiranja sadržaja uvođenjem mehanizma „*obavješćivanja i djelovanja*“. [Vijesti EU parlamenta, 2022]
    - **Naglašavanje ekstremnog ili senzacionalnog sadržaja**, kako bi se privukla pozornost korisnika i pojačala njihova angažiranost platforme su sklone naglašavati sadržaj koji prema tome vodi. Glavna nit koja vodi prema regulaciji ovog područja je činjenica kako društvene mreže nisu odgovorne za ono što korisnici govore, međutim odgovorne su za ono što odluče pojačavati bilo kroz ponuđene rezultate pretraživanja u tražilicama, redoslijedom prikaza u izborniku sadržaja vijesti (engl. *feed*) ili davanjem preporuka.
    - **Potencijal ovisnosti**, život u modernom društvu okružen tehnološkim novotarijama stvara i nove izvore ovisnosti kojeg se može i ne mora biti svjestan. Ovisnost se povezuje s razinom dopamina kojeg se često naziva i hormonom sreće ili hedonističkim hormonom koji se stvara kada se nagrađujemo s nečim što volimo, nečim u čemu uživamo, poput: gledanja omiljene serije, druženja s obitelji ili prijateljima, omiljena hrana ili slastica i sl. Društveni mediji pružaju mogućnost dobivanja beskrajne količina trenutačnih nagrada uz relativno mali ili nikakav trud. Kada se dobije personalizirana obavijest, znak sviđanja (engl. *lajk*) ili spominjanja (engl. *mention*) dolazi do navale dopamina, odnosno ugode i zadovoljstva. Cilj je platformi društvenim mreža da zadrže pažnju ili angažman korisnika što duže čime se povećava njihova izloženost oglasima, omogućava generiranja više podataka i naravno, platformama stvara veći profit [Ienca, 2023]. Pažnja se zaokuplja

aktivnostima koje na zahtijevaju veliki trud a pružaju ugodu, kao što su beskrajni sadržaj koji se automatski prikazuje bez pretraživanja i od kojeg se teško odmaknuti. Prikazom sadržaja upravlja umjetna inteligencija i predlaže se temeljem prijašnjih aktivnosti i iskazanih interesa, poruke su personalizirane i traže konstantnu provjeru platformi kako se nešto ne bi propustilo. Sve to upućuje na vrlo veliki manipulativni potencijal društvenih mreža.

- **Psihološko ciljanje (profiliranje)**
  Psihološko ciljanje odnosi se na stvaranje psiholoških profila temeljem prikupljanja i analize podataka o demografskim, bihevioralnim ili psihografskim karakteristikama korisnika – potrošačima. Svako korištenje digitalne tehnologije ostavlja određeni trag ili digitalni otisak koji može poslužiti za analizu ponašanja korisnika, ali i identificiranje njihovih osobnosti prema kojima se mogu krojiti posebne visoko personalizirane poruke [Sharp et al., 2018]. S obzirom da se koriste osobni podaci javlja se i zabrinutost zbog potencijalne manipulacije potrošačkim i političkim ponašanjima [Wilson, 2017].

- **Digitalno poticanje ili gurkanje (engl. *nudging*)**
  Tehnika poticanja ili gurkanja, kao što je ranije navedeno, primjenjuje se i u digitalnom okruženju „*s ciljem utjecaja na procese donošenja odluke kroz automatizirani odabir i rangiranje sadržaja*“. [Jesse, Jannach, 2021] Bazično se veže za dizajn korisničkih sučelja različitih aplikacija putem kojeg se utječe na odabir korisnika, ali i na kreiranje sustava preporuka koji mogu pored svojeg primarnog cilja olakšavanja izbora i donošenja odluke imati i sekundarni (sakriveni) cilj kojim se određene opcije u izboru izostavljaju, a druge se više ističu i vidljivije su.

- **Duboke laži (engl. *deepfake*)**
  Termin duboke laži (engl. *deepfake*) složenica je riječi duboko učenje (engl. *deep learning*) i laži (ono što nije originalno, nije autentično) (engl. *fake*) i odnosi se na digitalno stvoren videozapis kojeg je vrlo teško razlikovati od originala. Radi se o tehnologiji gdje se umjetna inteligencija koristi za montiranje lažnih video zapisa u kojima se prikazuju pojedinci kako rade i govore ono što nisu radili niti rekli. Tehnologija se koristi za zabavu (video snimke u kojima se ljudi predstavljaju kao poznate osobe vrlo su popularne na TikToku, kao i prikaz mogućnosti razgovora s preminulim voljenim osobama), ali i za ozbiljne manipulacije javnim mišljenjem, širenjem lažnih vijesti, krađu identiteta, kibernetički kriminal i diskreditaciju javnih i poznatih osoba.

Iz iznesenih primjera vidljivo je kako digitalno okruženje, pored svih blagodati i olakšavanja svakodnevnog života, kreira i mnoštvo zamki. Korištenje umjetne inteligencije (strojnog učenja) te zamke vješto sakriva te ih ljudi često nisu niti svjesni. Vrlo vješto se prikupljaju informacije o korisnicima kako bi se iste iskoristile za personalizirano ciljanje i utjecaj na njihovo ne namjerno ponašanje, odnosno na način da se „*zaobiđu njihove racionalne obrane i njihova sposobnost odbijanja tog utjecaja*“ [Ienca, 2023].

3. SMANJIVANJE RIZIKA OD DIGITALNE MANIPULACIJE

U definiranju aktivnosti koje bi se trebale provoditi u smislu smanjivanja rizika od digitalne manipulacije bitno je krenuti od nekoliko osnovnih činjenica koje su dotaknute i u prijašnjem tekstu a koje se odnose na realnost digitalnog okruženja, to su: [Max-Planck-Society, 2021]

- **Obmanjujući, tamni ili mračni obrasci** (engl. *dark patterns*), ponašanje korisnika pod utjecajem je arhitekture manipulativnog izbora koja se manifestira kroz tzv. obmanjujuće obrasce. Obmanjujući obrasci definiraju se kao trikovi koji se koriste na internetskim stranicama i u aplikacijama kako bi se korisnici natjerali da rade stvari koje nisu namjeravali [Cara, 2019].

  Cara (2019) u svojem istraživanju detektira 22 tipa ili oblika obmanjujućih obrazaca [Cara, 2019], dok ih Smjernice Europskog odbora za zaštitu podataka prikazuje kroz šest osnovnih grupa: [EDUS, 2023]
  - **Preopterećenje** (engl. *overloading*), korisnici dobivaju mnoštvo informacija s ciljem generiranja više osobnih podataka, više nego je potrebno u svrhu obrade, ili ih se opetovanim traženjem želi nagovoriti (prisiliti) da pristanu na novu svrhu obrade njihovih osobnih podataka. Najčešće pod takvim pritiscima korisnici i popuste
  - **Preskakanje** (engl. *skipping*), sučelje ili korisničko putovanje kreira se na način da se skrene pozornost korisnika s problematike zaštite osobnih podataka
  - **Miješanje** (engl. *stirring*), riječi i vizualni elementi se prikazuje na način da utječu na korisničke emocije kako bi se skrenula pozornost s radnji u svezi zaštite osobnih podataka (npr. mala slova ili tekst u bojama koje nisu dovoljno kontrastne)
  - **Ometanje** (engl. *obstructing*), ometanje ili blokiranje korisnika u informiranju i radnjama upravljanja njihovim osobnim podacima ili davanje pogrešnih informacija s ciljem dobivanja nepotrebnih osobnih podataka
  - **Nestalnost** (engl. *fickle*), dizajn sučelja je nedosljedan i nejasan, što korisnicima otežava navigaciju i pronalaženje određenih funkcija
  - **Ostavljen u mraku** (engl. *left in the dark*), odnosi se na sučelja koja skrivaju informacije ili alate za kontrolu zaštite podataka.

- **Personalizacija pokretana umjetnom inteligencijom,** kako bi se u sve dominantnijem digitalnom okruženju tvrtke što bolje povezale sa svojim klijentima i osigurale njihovo što duže zadržavanje nastoje im pružiti odgovarajuće personalizirano korisničko iskustvo. U tome im danas pomaže umjetna inteligencija i veliki podaci (engl. *big data*), temeljem prikupljanja i analize velikih količina strukturiranih i nestrukturiranih podataka koje korisnici svojim ponašanjem u digitalnom svijetu generiraju (povijest pregledavanja, kupnji, interakcije na društvenim mrežama, demografski podaci i dr.) izrađuju se predikacijski modeli, odnosno modeli kojima se predviđa njihovo buduće ponašanje. Obradom povijesnih podataka korisnika dolazi se do informacija o njihovim specifičnim potrebama i interesima koje se koriste za kreiranje personaliziranih korisničkih iskustva. Sustavi preporuka za to su najbolji primjer, rezultati pretraživanja u tražilicama neće biti isti za dvije osobe, preporučeni video zapis na YouTubeu neće biti isti i sl. Prednosti takve personalizacije u kojoj umjetna inteligencija ima dominantnu ulogu su: poboljšanje korisničkog iskustva, povećanje prihoda, smanjeni odljev korisnika i uvidi temeljeni na podacima [Zia, T., 2023].

  Koristi personalizacije za korisnika i za tvrtku su jasni i razumljivi, ali ono što korisnici ne primjećuju i čega u pravilu nisu svjesni je da su stavljeni u tzv. filter mjehur (engl. *filter bubbles)*, odnosno da se sadržaj filtrira prema njihovim preferencijama ili prema onome što sustav misli da bi ih zanimalo. Dolazi se na područje mogućih manipulacija i izolacija od drugačijih izbora, ideja, mišljenja i sl.

- **Lažne informacije i dezinformacije**, poslovna politika ili poslovni modeli platformi društvenih medija temelje se na što većoj prisutnosti i angažiranosti korisnika koja izravno vodi i većoj zaradi od oglašavanja. To znači da je potrebno zaokupiti pozornost korisnika te se u tom smislu prednost daje sadržajima koji će osigurati visoku angažiranost i virilnost. Takvi su sadržaji često i upitne vjerodostojnosti, a da su korisnicima društvenih medija zanimljivi potvrđuje i istraživanje Vosounghi i sur. (2018) koji su utvrdili kako se laž širi brže, dalje i šire od istine [Vosoughi, 2018]. Činjenica je kako pozornost bolje privlači sadržaj koji je kontraverzan, senzacionalistički i iznenađujući te koji potvrđuje nečija postojeća uvjerenja ili predrasude, potiče emocije i vizualno je upečatljiv [Medijska pismenost, 2023]. To je i razlog da se dezinformacije i lažne vijesti (poput teorija zavjere) zbog svoje atraktivnosti i (lažne) vjerodostojnosti lako zamjećuju i dijele. Štetni sadržaji kreiraju informacijski poremećaj koji ljudima onemogućava razlikovanje istinitih od lažnih informacija, što vodi prema nepovjerenju prema tradicionalnim medijima (engl. mainstream) i davanju povjerenja alternativnim medijima upitne vjerodostojnosti. Zanimljivo je kako većina takvog sadržaja nije lažna već je izvučena iz konteksta, ili se temelji na glasinama, ili je sadržaj previše pristran, ili su određene ključne informacije izostavljene [Nenadić, Vučković, 2021]. Također je bitno, naročito za digitalne medije, kako su različiti vizuali, naročito memovi, puno uvjerljiviji od teksta, a time i efikasan način širenja dezinformacija i pogrešnih informacija.

- **Ometajuće okruženje,** kao što je spomenuto cilj je platformi društvenih medija zaokupiti pažnju korisnika što je duže moguće i osigurati njihovu što veću angažiranost. U ispunjavanju tog cilja služe se različitim tehnikama od obavijesti, skočnih oglasa, stalnog ažuriranja sadržaja i sl. Ta negativna strana društvenih medija može imati vrlo veliki, a ujedno i neprimjetan utjecaj na korisnike, naročito mlađe generacije, čija se pažnja odvlači s drugih važnijih stvari i time stvara ovisnost.

Aktivnosti smanjivanja rizika od digitalne manipulacije odvijaju se u nekoliko smjerova: [Ienca, 2023]

- **Obrazovanje korisnika i digitalna pismenost**

  Nužno je da korisnici budu upoznati s oblicima i tehnikama manipulacije kako bi je bili svjesni i po potrebi mogli izbjeći. U tome je njihovo kritičko razmišljanje najbitnije. Kritičko razmišljanje predstavlja „*intelektualno disciplinirani proces aktivnog i vještog konceptualiziranja, primjene, analiziranja, sintetiziranja i/ili evaluacije informacija prikupljenih ili generiranih, promatranjem, iskustvom, promišljanjem, rasuđivanjem ili komunikacijom*“ [Libertas, 2022]. Ono uključuje više vještina: verbalno zaključivanje, analizu argumenata, razmišljanje kao testiranje hipoteza, suočavanje s vjerojatnostima i neizvjesnostima te vještine donošenja odluka i rješavanja problema [Machete, Turpin, 2020]. U kontekstu predmetne teme može se definirati kao „*sposobnost analiziranja i vrednovanja argumenata prema njihovoj utemeljenosti i vjerodostojnosti, reagiranje na argumente i dolaženje do zaključka kroz dedukciju dobivenih informacija*“. [Taala et al., 2019] Jednostavno rečeno kritičko razmišljanje predstavlja namjernu i sustavnu obradu primljenih informacija s ciljem njihovog boljeg razumijevanja i donošenja određenih odluka.

  S obzirom na značaj tehnologije u svakodnevnom životu i njezinoj ulozi u društvenoj interakciji, poslovanju i obrazovanju u prvi se plan ističe i digitalna pismenost građana koja treba omogućiti lakše i sigurnije snalaženje u prenatrpanom digitalnom svijetu. U tom smislu digitalna se pismenost odnosi na posjedovanje vještina koje će omogućiti život i rad u okruženju gdje se komunikacija i pristup informacijama odvija putem digitalnih

tehnologija. To se odnosi kako na tehničke vještine tako i na vještine prolaženja informacija, njihovog vrednovanja, stvaranja i prenošenja, ali i zaštite osobnih podatka i zaštite od raznih online prijetnji.

U kontekstu digitalne pismenosti naglašava se i medijska pismenost kao ključna vještina potrebna za snalaženje u današnjem digitalnom svijetu. Mnoštvo informacija koje su dostupne i nadohvat „*klika*“ potrebno je moći procijeniti, procesuirati, odvojiti loše od dobrih i pametno koristiti. Dakle, sposobnost obrade i evaluacije informacija iz različitih medijskih izvora naziva se medijska pismenost [Lynch, 2023].

Potrebu za medijskom pismenošću potvrđuje i praksa medijskih kuća koje se manipulacijom koriste na različite načine, najčešće: [Ashford, 2022]

- **Iskorištavanjem emocionalne ranjivosti**, mediji vrlo dobro znaju da tri osnovne ljudske emocije (ljutnja, strah i požuda) izazivaju pozornost i doprinose vraćanju na njihove stranice. I tek usputni pogled na današnje medijske portale može detektirati utjecaj na te emocije kako bi se potaknule određene reakcije
- **Tiskanjem „vijesti“ koje to nisu**, fabriciranje vijesti temeljem nekih mišljenja, a ne činjenica ili opterećivanje činjenica mišljenima ili tendencioznim komentarima
- **Iznošenje neistina u svrhu difamacije osoba**, uništavanje ugleda osoba pri čemu se ne biraju sredstva, odnosno nije bitno jesu li iznesene stvari istinite ili ne
- **Etiketiranjem osoba**, etiketiranjem osoba koje su meta ili koje mediji ne vole (komunist, fašist, rusofil i sl.) javno se „*uništava*“ ugleda osoba koje se medijima na sviđaju.
- **Korištenje istinolikosti** *(engl. verisimilitude),* receptura koju mediji vrlo perfidno koriste, a odnosi se na doziranje neistina, odnosno stalni prikaz malo neistine u kombinaciji s istinom. Kada se medij probija na medijskom tržištu istina je više kako bi se steklo povjerenje
- **Sendvič neprijateljstva**, kada se nešto dobro učinjeno ili rečeno želi zamagliti i ne previše istači. U pravilu se takva informacija stavlja između dvije negativne (neistinite ili negativno komentirane) informacije
- **Namještena rasprava ili panel**, kada se pozivaju gosti (komentatori) za određenu temu pažljivo se bira njihov sastav kako bi se unaprijed definirali rezultati rasprava ili krajnji zaključak panela.
- **Ponavljanje neistina ili laži**, konstantno ponavljanje neistina omiljeni je način djelovanja medija koji vodi prema konačnom prihvaćanju neistine kao istine
- **Ismijavanje javnih osoba** (engl. *lampooning*), prikazivanje javnih osoba kroz crteže i fotografije na humoristični ili sarkastičan način tako da ispadnu tupe ili glupe
- **Manipulacija fotografijom**, moderni digitalni fotoaparati omogućavaju slikanje velikom brzinom prilikom čega se može uloviti svaki trenutak u nečijem govoru ili nekoj radnji. Odabire se ona fotografija kojom ga se želi oslikati i prikazati na određeni način, pozitivno ili negativno. Primjera takve neobjektivnosti i manipulacije publikom je napretek.

Vještine medijske pismenosti koje će omogućiti spoznaju oblika manipulacije medija mogu se sagledati kao: [Lynch, 2023]

- **Vještine postavljanja pitanja**, postavljenjem pitanja preispituje se pouzdanost, valjanost i pristranost informacija koje se konzumiraju

- **Vještine pretraživanja i istraživanja**, važna vještina koja će omogućiti određivanje vjerodostojnosti i pouzdanosti izvora informacija
- **Vještine kritičkog razmišljanja,** omogućavaju da se informacije i razne medijske poruke točno protumače
- **Vještine analize**, sposobnost razumijevanja načina stvaranja i širenja medijskih poruka
- **Vještine evaluacije**, mogućnost određivanja vjerodostojnosti različitih medijskih izvora, poput blogova, internetskih stranica, videozapisa, profila na društvenim mrežama i sl.
- **Vještine etike i odgovornosti**, svijenost o etičnom i odgovornom poslovanju na internetu, kao i razumijevanje regulative o ponašanju i sigurnosti na internetu.
- **Vještine refleksije i samoprocjene**, razumijevanje utjecaja digitalnog okruženja i medijskih izvora na svakodnevni život i pozitivnom doprinosu medijskom sadržaju.

- **Transparentnost primjene umjetne inteligencije**

Umanjenju zabrinutosti u svezi manipulacija koje primjena umjetne tehnologije može uzrokovati doprinosi i transparentnost same tehnologije, u ovom slučaju rada algoritama i načinima prikupljanja, obrade i korištenja podataka te donošenja odluka.

Algoritamski sustavi programirani su za ostvarivanje određenih ciljeva i mogu se promatrati kao „crne kutije“ gdje su izlazi u obliku predviđanja, preporuka ili odluka korisniku vidljivi, međutim način rada samog sustava korisniku je nepoznat, odnosno nije ga u stanju protumačiti. Promatranje tih sustava kao „crne kutije“ gdje ima mnoštvo nepoznanica vodi prema njihovoj netransparentnosti. Stoga se predlaže za objašnjenje i bolje razumijevanje umjetne inteligencije umjesto „*crne kutije*“ koristiti tzv. pristup „*Cetaris paribus*“ (prijevod: pod jednakim uvjetima ili sve ostalo nepromijenjeno) koji je prema Lenca (2023) manje manipulativni. „*U osnovi ljudima je teško vjerovati „crnoj kutiji“ prvenstveno iz razloga što umjetna inteligencija ima loše rezultate u donošenju nepristranih odluka ili rezultata*“ [Lawton, 2023].

Transparentnost se može definirati na različite načine, kada se govori o modelima umjetne inteligencije to se odnosi na sposobnost uvida u rad modela i razumijevanje načina na koji donosi odluke. Prije spomenuta pristranost rezultata ili odluka koje se javljaju kao rezultat rada algoritama proizlazi iz samog načina njihovog rada ili treniranja na velikim količinama podataka koji su ipak pod određenom kontrolom čovjeka. Kao primjer se navodi diskriminacijski algoritam tvrtke Amazon koji se prestao koristiti kao alat za zapošljavanje nakon spoznaje da su se za određena tehnička radna mjesta favorizirali kandidati muškog spola, nauštrb kandidatkinja ženskog spola [Forbes 2021]. Na kritiku javnosti naišao je i Twitterov sustav za obrezivanje fotografija 2020. godine koji je navodno diskriminirao crnce i žene te se fokusirao na ženske grudi i noge. Twiter je reagirao na optužbe pokretanjem interne istrage te je cjelovito tehničko izvješća o rezultatima istrage dao na uvid javnosti [Engineering, 2021]. Primjera algoritamske pristranosti ima mnogo, a oni proizlaze iz načina tretiranja ili učenja algoritama pri čemu korišteni podaci nisu bili dovoljno uravnoteženi i nisu uključivali dovoljno podataka o svim vrstama ljudi. Činjenica je kako kompleksni sustavi i algoritmi dubokog učenja ne mogu biti potpuno transparentni, ali bi trebali omogućiti ljudima uvid u način na koji su donijeli određenu odluku, na primjer, ako se nekome odbije socijalna pomoć, kredit ili osiguranje osoba bi trebala biti obaviještena o razlogu donošenja takve odluke i dobiti upute što da učini kako bi se ta odluka osporila.

Upravo je potencijalna pristranost algoritama uz povjerenje i mogućnost provjere njihovog rada osnovni razlog isticanja problematike transparentnosti u radu umjetne inteligencije. „*Bez transparentnosti riskiramo stvaranje sustava umjetne inteligencije koji bi mogli nenamjerno produžiti štetnu pristranost, donijeti nedokučive odluke ili čak dovesti do neželjenih ishoda u visokorizičnim aplikacijama*“. [Engineering, 2021]

- **Regulatorni nadzor**
  Ubrzani razvoj digitalnih usluga, digitalnog tržišta i tehnologija umjetne inteligencije Europska unija svojom zakonskom regulativom nastoji regulirati. Dva su akta u tom smislu posebno zanimljiva: Akt o digitalnim uslugama i Akt o umjetnoj inteligenciji.

  Akt o digitalnim uslugama stupio je na snagu 16. studenog 2022. godine i primjenjuje se zajedno s Uredbom (Aktom) o digitalnim tržištima. Regulativa vezana za digitalne usluge uređuje područje internetskog sadržaja i zaštite korisnika, dok regulativa na području digitalnog tržišta nastoji spriječiti velike i utjecajne kompanije da se ponašaju nepošteno i ugrožavaju konkurenciju. Uredba se temelji na dva osnovna načela: prvo, „*što veća platforma to veća odgovornost*“ i drugo, da po pitanju protuzakonitog i nepoštenog poslovanja nema razlike između poslovanja izvan i unutar digitalnog okruženja i jedno i drugo je van zakona te kao takvo nedopustivo. Uređivanje odgovornosti pružatelja digitalnih usluga koji su posrednici između potrošača i roba, usluga i sadržaja treba voditi boljoj zaštiti korisnika i njihovih temeljnih prava na internetu, ali i uvjetovati veću transparentnost i odgovornost internetskih platformi [IUS-INFO, 2023].

  Akt o umjetnoj inteligenciji novi je europski zakon koji bi uskoro trebao biti donesen, predstavlja prvi pravni okvir o umjetnoj inteligenciji koji bi trebao osigurati sigurno, transparentno, etično i nepristrano korištenje te tehnologije. Akt ima zadatak uspostave povjerenja Europljana prema onome što tehnologije umjetne inteligencije nude. Prijedlog regulacije polazi od klasificiranja sustava umjetne inteligencije u skladu s razinom rizika kojeg donose. Pored sustava umjetne inteligencije koji ne predstavljaju nikakav ili minimalan rizik i svojim radom pomažu u rješavanju različitih svakodnevnih zadataka postoje i sustavi visokog rizika čije zanemarivanje može uzrokovati neželjene ishode za cijelo društvo. Često se govori i o „*piramidi rizika*“ koja sadrži četiri kategorije rizika sustava umjetne inteligencije: neprihvatljivog, visokog, ograničenog i minimalnog rizika. Neprihvatljiv rizik, odnosno korištenje sustava umjetne inteligencije koje Akt prepoznaje kao neprihvatljive se zabranjuje. Na primjer, društveno bodovanje (engl. *social scoring*), kognitivna bihevioralna manipulacija ljudi ili određenih ranjivih skupina, subliminalne tehnike, daljinska biometrijska identifikacija u javnim (otvorenim) prostorima i predviđanje kriminalnog ponašanja.

- **Etičnost umjetne inteligencije**
  Nagli razvoj umjetne inteligencije nesumnjivo donosi velike blagodati i koristi i pojedincima i društvu u cjelini, međutim izaziva i vrlo duboku etičku zabrinutost. Uobičajena definicija etiku definira kao skup moralnih principa koji pomažu u donošenju odluka o tome što je dobro (ispravno), a što loše ili neispravno. Vezano na tu definiciju etika umjetne inteligencije može se definirati kao skup moralnih ideja i strategija osmišljenih s ciljem odgovarajuće primjene tehnologija umjetne inteligencije [Sakti, 2022]. Pored odgovarajuće primjene tehnologija umjetne inteligencije etičnost uključuje i informiranje o njihovom korištenju s obzirom da je njezina prisutnost i integracija u proizvodima i uslugama sve veća. U tom smislu tvrtke donose i svoje etičke kodekse ili vrijednosne platforme umjetne inteligencije, kojima transparentno iznose svoje politike

njezinog korištenja te smjernicama pomažu korisnicima donošenje odluka kada su suočeni s etičkim dvojbama korištenja istih.

Kao što je već rečeno na području Europske unije u proceduri je donošenja i Akt o umjetnoj inteligenciji koji ima zadatak stvoriti regulatorni okvir za sustave umjetne inteligencije i njihov etički razvoj usmjeren na čovjeka.

4. ZAKLJUČAK

Ubrzani razvoj i primjena umjetne inteligencije u svim sferama ljudskog života izaziva i određene (opravdane) strahove od njezinog negativnog i manipulativnog utjecaja. Prepoznavanjem snage umjetne inteligencije pokreću se i aktivnosti na donošenju regulatornih okvira njezinog daljnjeg razvoja i korištenje. Prvi korak u globalnoj regulaciji tog područja poduzima UNESCO 2021. godine donoseći Preporuke o umjetnoj inteligenciji te Europska unija donošenjem Akta o digitalnim uslugama i prijedlogom Akta o umjetnoj inteligenciji.

Centralno mjesto u UNESCO-vim Preporukama zauzimaju etička načela usmjerena prema zaštiti ljudskih prava i ljudskog dostojanstva. Akt o umjetnoj inteligenciji, koji je u fazi usuglašavanja, u regulaciji polazi od klasificiranja sustava umjetne inteligencije u skladu s razinom rizika kojeg donose. Često se govori i o tzv. piramidi rizika na čijem se vrhu nalaze sustavi neprihvatljivog rizika ili sustavi umjetne inteligencije koji predstavljaju jasnu prijetnju sigurnosti, sredstvima za život i pravima ljudi te se kao takvi zabranjuju.

Namjera zaštite od negativnog i potencijalnog štetnog utjecaja umjetne inteligencije na području Europske unije je jasna, međutim istovremeno se otvara i pitanje mogućeg ograničavanja njezinog daljnjeg razvoja koji bi Europu mogao usporiti i dovesti u nepovoljan položaj prema ostatku razvijenog svijeta.

REFERENCE

[1] Aarts H., Dijksterhuis A., DeVries P. On the psychology of drinking: Being thirsty and perceptually ready. *Br. J. Psychol.* 2001;92, pp 631–642.

[2] Anderere, J. (2023), Bots run rampant on social media, and most people can't tell the difference anymore, https://studyfinds.org/bots-social-media-fake-accounts/, pristupljeno kolovoz 2023.

[3] Ashford, B. (2022), Manipulation 102: How to Spot Media Manipulation and Block its Effects, https://bruceashford.net/2022/manipulation-102-how-to-spot-media-manipulation-and-block-its-effects/, pristupljeno kolovoz 2023.

[4] Ashton, H., Franklin, M. 2022. The problem of be-haviour and preference manipulation in AI systems. In The AAAI-22 Workshop on Artificial Intelligence Safety (SafeAI2022) *Missing Mechanisms of Manipulation in the EU AI Act*., dostupno na: https://www.researchgate.net/publication/360383263_Missing_Mechanisms_of_Manipulation_in_the_EU_AI_Act#fullTextFileContent

[5] Bermudez, J.P., Nyrup, R., Deterding, R., Moradbakti, L., Mougenot, C., You, F., (2023), What Is a Subliminal Technique? An Ethical Perspective on AI-Driven Influence, *Conference: 2023 IEEE International Symposium on Ethics in Engineering, Science, and Technology* (ETHICS)

[6] Cara, C. (2019), Dark Patterns in the Media: A Systematic Review, *Network Intelligence Studies,* Volume VII, Issue 14 (2/2019)
[7] CareerCentar (2019), što je nudge i zašto svi o tome pričaju?, https://careercentar.com/objava/491, pristupljeno, kolovoz 2023.
[8] Carnet (2023), Steganografija, https://www.cert.hr/wp-content/uploads/2006/06/CCERT-PUBDOC-2006-04-154.pdf, pristupljeno srpanj 2023.
[9] CEU (2022), Interinstitutional File 2021/0106 (COD), Brissels, 25.11.2022.
[10] EDUS (2023), Kako prepoznati i izbjeći „mračne obrasce" na društvenim mrežama, https://www.edusinfo.hr/aktualno/u-sredistu/kako-prepoznati-i-izbjeci-mracne-obrasce-na-drustvenim-mrezama-smjernice-europskog-odbora-za-zastitu-podataka-54585, pristupljeno kolovoz 2023.
[11] Engineering (2021), Sharing Learnings about our image cropping algorithm, https://blog.twitter.com/engineering/en_us/topics/insights/2021/sharing-learnings-about-our-image-cropping-algorithm, pristupljeno kolovoz 2023.
[12] European Commission (2021), *Proposal for a regulation of the European Parliament and of the Concil*, Brussels, 21.04.2021.
[13] Forbes (2021), Overcoming AI's Transparency Paradox, https://www.forbes.com/sites/aparnadhinakaran/2021/09/10/overcoming-ais-transparency-paradox/?sh=5c0ea2864b77, pristupljeno, kolovoz 2023.
[14] Franklin, M., Ashton, H., Gorman, R., Armstrong, 'Missing mechanisms of manipulation in the EU AI Act', *Int. FLAIRS* Conf. Proc., vol. 35, May 2022
[15] Ienca M., Malgieri G. (2022) Mental data protection and the GDP,. *J Law Biosci* 9(1)
[16] Ienca, M. (2023), On Artificial Intelligence and Manipulation. *Topoi* **42**, 833–842 (2023)
[17] IUS-INFO (2023), Nova regulativa digitalnih usluga, https://www.iusinfo.hr/aktualno/u-sredistu/nova-regulativa-digitalnih-usluga-53882, pristupljeno kolovoz 2023.
[18] Jesse, M., Jannach, D. (2021). Digital nudging with recommender systems: Survey and future directions. *Computers in Human Behavior Reports*, 3, 100052.
[19] Jesse, M., Jannach, D. (2021). Digital nudging with recommender systems: Survey and future directions. *Computers in Human Behavior Reports*, 3 / 2021
[20] Kaplan, A. M., Haenlein, M. (2010) Users of the world, unite! The challenges and opportunities of social media. *Business Horizons*, 53 (1), 59–68.
[21] Lawton, G. (2023), AI transparency: what i sit and why do we need it, https://www.techtarget.com/searchcio/tip/AI-transparency-What-is-it-and-why-do-we-need-it, pristupljeno, kolovoz 2023.
[22] Lenca, M. (2018), https://blogs.scientificamerican.com/observations/cambridge-analytica-and-online-manipulation/, pristupljeno. kolovoz 2023.
[23] Libertas (2022), Kako razvijati kritičko razmišljanje, https://www.libertas.hr/za-studente/kako-razviti-kriticko-razmisljanje/, pristupljeno kolovoz 2023.
[24] Lynch, M. (2023), What are the 7 skills of media literacy, https://www.theedadvocate.org/what-are-the-7-skills-of-media-literacy/, pristupljeno kolovoz 2023.
[25] Machete, P., Turpin, M. (2020), The Use of Critical Thinking to identify Fake News: A systematic literature Review, *IFIP International Federation for Information Processing*, pp 235-246
[26] Max-Planck-Society (2021), Protecting ourselves against Internet manipulation, https://www.mpg.de/16408566/0211-bild-citizens-versus-the-internet-how-can-we-protect-ourselves-against-manipulation-fake-news-and-other-digital-challenges-149835-x, pristupljeno, kolovoz 2023.

[27] Medijska pismenost (2023), Razlike između dezinformacije, misinformacije i malinformacije, https://www.medijskapismenost.hr/razlike-izmedu-dezinformacija-misinformacija-i-malinformacija/, pristupljeno, kolovoz 2023.
[28] Metcalfe, J. J., Ellison, B., Hamdi, N., Richardson, R., & Prescott, M. P. (2020). A systematic review of school meal nudge interventions to improve youth food behaviors. *International Journal of Behavioral Nutrition and Physical Activity*, 17(1).
[29] Nenadić, I, Vučković, M. (2021), *Dezinformacije, edukativna brošura i vježbe za razumijevanje problema dezinformacija*, Agencija za elektroničke medije i UNICEF, Zagreb, str. 7.
[30] Neuwirth, J.R. (2022), https://news.cgtn.com/news/2022-02-08/AI-and-human-mind-Manipulation-and-dangers-of-subliminal-AI-systems--17sA7bWEU5G/index.html, pristupljeno, kolovoz 2023.
[31] Quantamagazine (2023), Secret Messages Can Hide in AI-Genereted Media, https://www.quantamagazine.org/secret-messages-can-hide-in-ai-generated-media-20230518/,pristupljeno srpanj 2023.
[32] Sakti, J. (2022.), Al value platform, https://www.linkedin.com/pulse/ai-value-platform-sakti-jena-b-tech-mba-cspo/, pristupljeno rujan 2023.
[33] Schneider, C., Weinmann,M., J. vom Brocke, Digital nudging: Guiding online user choices through interface design, *Communications of the ACM*, 61 (2018),
[34] Sharp, B., Danenberg, N., Bellman, S. (2018). Psychological targeting, PNAS, vol 115(34)
[35] Shih, F.Y. (2017), *Digital Watermarking and Steganogrphy: Fundamentals and Techniques* (Second Edition), CRC Press, NW, str.5.
[36] Susser D, Beate R, Helen N (2019) Technology, Autonomy, and Manipulation. *Internet Policy Rev* 5:35
[37] Taala, W., Franco Jr., F.B., Teresa, P.H.S. (2019), Library literacy program: library as battleground for fighting fakenews. *Open Access Libr. J*ournal 6(03), 1-16
[38] Thaler R.H, Sunstein C.R, Balz .JP (2010) Choice architecture. SSRNElectron J., https://www.researchgate.net/publication/314570601_Digital_Nudging#fullTextFileContent, pristupljeno, kolovoz 2023.
[39] The Future of Life Institute, (2022), Manipulation and the AI Act, https://futureoflife.org/wp-content/uploads/2022/01/FLI-Manipulation_AI_Act.pdf, pristupljeno kolovoz 2023.
[40] The Wall Street Journal (14.09.2021.), Facebook Knows Instagram Is Toxic for Teen Girls, Company Document Show, https://www.wsj.com/articles/facebook-knows-instagram-is-toxic-for-teen-girls-company-documents-show-11631620739, pristupljeno, kolovoz 2023.
[41] UNESCO (2023), Recommendation on the Ethic of Artificial Intelligence, https://www.unesco.org/en/legal-affairs/recommendation-ethics-artificial-intelligence, pristupljeno, kolovoz 2023.
[42] UNESCO (2023a), AI: UNESCO calls on all Governments to implement Global Ethical Framework to implement Global Ethical Framework without deley, https://www.unesco.org/en/articles/artificial-intelligence-unesco-calls-all-governments-implement-global-ethical-framework-without, pristupljeno, kolovoz 2023.
[43] Vijesti EU parlamenta, (2022), Suzbijanje štetnog i nezakonitog sadržaja na internetu: ideje Parlamenta, https://www.europarl.europa.eu/news/hr/headlines/economy/20201022STO89919/suzbijanje-stetnog-i-nezakonitog-sadrzaja-na-internetu-ideje-parlamenta, pristupljeno, kolovoz 2023.

[44] Vosoughi, S., Roy, D., Aral, S. (2018). The spread of true and false news online. *Science Journals*, 359, str. 1146–1151.
[45] Weinmann, M., Schneider, C., Brocke, J. vom. (2016). *Digital Nudging. Business & Information Systems Engineering*, 58(6), 433–436
[46] Wilson DG (2017) The ethics of automated behavioral microtargeting. *Ai Matters* 3(3), 56–64
[47] Zia, T. (2023), AI-Powered Personalization: How Machine Learning is Transforming Customer Experience https://www.techopedia.com/ai-powered-personalization-how-machine-learning-is-transforming-customer-experience, pristupljeno kolovoz 2023.

Professional paper / Stručni rad

KORIŠTENJE ASERTIVNE TEHNIKE U PRODAJNOM POSLOVANJU

SANDRA MRVICA MAĐARAC
Veleučilište „Lavoslav Ružička“ u Vukovaru
Županijska 50, 32000 Vukovar, Hrvatska
smrvica@vevu.hr

ZVONIMIR FILIPOVIĆ
PIK Vrbovec plus d.o.o.
Gospodarska zona 20, 31216 Antunovac, Hrvatska
zvonimir88@gmail.com

SLAĐANA BRAJEVIĆ
Sveučilišni odjel za stručne studije
Kopilica 5, 21000 Split, Hrvatska
sladjana.brajevic@oss.unist.hr

SAŽETAK

Suvremeno prodajno poslovanje podrazumijeva različite tehnike u prodajnom procesu kako bi se zadržali postojeći kupci i privukli novi kupci. Uz pomoć različitih tehnika koje se koriste u prodaji prodajni proces se maksimizira i postaje održiv. Pojam asertivnost podrazumijeva samosvjesnost, samopouzdanost i samouvjerenost, a predstavlja idealno ponašanje učinkovitog djelatnika u prodaji.

Koristeći asertivnu prodajnu tehniku djelatnici u prodaji razvijaju dugoročno održiv i učinkovit poslovni odnos s kupcima jasno iznoseći vlastite zahtjeve, ali istovremeno i poštujući zahtjeve kupca. Asertivnost prodajnog menadžmenta je važna u poslovanju jer podrazumijeva dvosmjernu komunikaciju i samosvjesnost s obje strane kako bi se na taj način izbjegle sve nejasnoće i eventualno poboljšali prijedlozi strateškog menadžmenta na temelju operativnog iskustvenog znanja prodajnog menadžmenta, a sve s ciljem što učinkovitijeg poslovanja.

U radu se definira pojam asertivne komunikacije, elementi i tehnike asertivne prodaje, glavne prednosti asertivnostog komuniciranja i prednosti koje donosi asertivnost kao tehnika prodaje. Za potrebe rada se provelo istraživanje putem anketnog upitnika među zaposlenicima u prodaji sa ciljem uvida koliko su upoznati sa asertivnim komuniciranjem i koliko primjenjuju asertivne tehnike u prodajnom poslovanju.

KLJUČNE RIJEČI: prodajno poslovanje, asertivnost, prodajne tehnike, poslovni odnos, istraživanje

1. UVOD

Kako bi bila uspješna trgovinska poduzeća moraju uz ostale prodajne tehnike usvojiti i asertivnost kao ključnu prodajnu tehniku. Promatrajući iz perspektive trgovinskog poduzeća asertivnost kao prodajna tehnika podrazumijeva određeni standard komunikacije na više razina. Strateški menadžment trgovinskog poduzeća mora na jasan, razumljiv, činjenično utemeljen i motivirajući način pred svoj prodajni menadžment iznijeti planove i očekivanja te jasno definirane ciljeve koji se žele ostvariti u definiranom vremenskom okviru.

Asertivnost na razini komunikacije između strateškog menadžmenta i prodajnog menadžmenta je izuzetno važna jer ona podrazumijeva dvosmjernu komunikaciju, samopouzdanost, samosvjesnost i samouvjerenost s obje strane kako bi se na taj način izbjegle sve nejasnoće i eventualno poboljšali prijedlozi strateškog menadžmenta na temelju operativnog iskustvenog znanja prodajnog menadžmenta, a sve s ciljem što učinkovitijeg poslovanja.
Za potrebe rada se provelo istraživanje putem anketnog upitnika sa ciljem uvida koliko zaposlenici u prodaji koriste asertivnost kao prodajnu tehniku.

2. ASERTIVNA KOMUNIKACIJA

Komunicirati znači dijeliti informaciju s drugima, a u tom procesu sudionici se međusobno obogaćuju. Komunikacijom se razmijenjuju misli, priopćavaju ideje i prenose poruke između osoba u užoj i široj okolini ili se uz pomoću interneta lako prenose kroz vrijeme i prostor [Lamza – Maronić, Glavaš, 2008]. Komunikacija se definira kao condicio sine qua non društvenog poretka [Watzslavick, 1976]. Komunikacija je nužna i temeljna pretpostavka svakog društva [Parsons, 1966; Luhman, 1972].

Komunikacijske poruke se mogu prenositi različitim komunikacijskim kanalima, koristeći i više od jednog istovremeno. Pored govorne (auditivne) komponente, poruka se može prenositi i olfaktornim kanalom (mirosom), vizualnim kanalom, gustacijskim (okus) te senzornim (dodir). Ovi senzorni kanali zapravo moduliraju procese odnosno kemiju proceduralnog pamćenja, te vezuju često emociju uz događaj, što može biti iznimni problematično ukoliko su vezani uz neugodna iskustva (miris trulog voća, vlage, neljubazno lice i slično). Evolucija je bila vrlo velikodušna kad je u pitanju osjet mirisa, tako da receptori za miris zauzimaju tri posto mjesta u našem genomu [Lehrer, 2012]. Istraživanjima sugeriraju kako neverbalni dio komunikacije često spada u važniji dio od verbalnog komuniciranja te da su ljudi skloni prosuđivati, pamtiti ili donositi zaključke više po neverbalnom nego po verbalnom govoru. Prema tomu vrijednost vizualna aspekta poruke (govor tijela) je: 55%, vizualnog (govor tijela), 38% glasovnog (kako kažemo) i 7%. verbalnog (što kažemo). Tako se pri prosudbi emocionalnog stanja osobe veća važnost pridaje izrazu lica nego verbalnim izjavama [Mehrabian, 2017]. Kad je govornik pripremljen posjeduje vještine dobrog izražavanja i neverbalne komunikacije, tada je vjerojatnije kako će duže vrijeme zadržati pažnju slušatelja što će se odraziti na njegovu uspješnost usvajanja upućenih mu informacija [Borovac Zekan, Gabrić, 2021].

Načini na koje se može komunicirati su: verbalno (govorno) izražavanje, neverbalno (kontaktno) izražavanje, pismena komunikacija i elektronska komunikacija. Verbalnim izražavanjem se prenose misli i poruke putem jezika kao najvažnijeg komunikacijskog sredstva. Neverbalna komunikacija koristi tijelo koje upotpunjuje usmeno izražavanje pomoću

neverbalnih znakova (zvukovi, ton glasa, miris, geste, izrazi lica, držanje, pokreti tijela, odjeća, nakit, udaljenost) [Lamza – Maronić, Glavaš, 2008]. Prednost verbalne komunikacije je brzina, a njeni oblici mogu biti: razgovor, diskusija, javno izlaganje i izvještavanje bilo jednoj osobi ili grupi ljudi [Fox, 2006].

U modelu komunikacijskog događaja sudjeluju: sugovornici, poruka, interpretacija i razumijevanje poruke, prijenosnik poruke, načini kojima se poruka razmijenjuje, uzvratni odgovor, opasnosti koje usporavaju komunikacijski događaj u bilo kojem njegovom dijelu [Lamza – Maronić, Glavaš, 2008]. Pravila dobre interpersonalne komunikacije su: komunicirati treba iskreno, ne koristiti neverbalne znakove koji remete komunikaciju, poštivati osobnosti sudionika komunikacije, vjerovati u ono što se govori na temelju provjerenih činjenica i podataka, međusobne odnose koji imaju potencijal da postanu konfliktni rješavati odmahvažnost tolerancije u komunikaciji, stjecati povjerenje pokazivanjem rada na vlastitom primjeru [Tudor, Srića, 2014].

Asertivnost je vještina koja pomaže da se izborimo za svoja prava, osiguravajući da se naše mišljenje uzme u obzir, a da se pri tome ne narušavaju prava drugih. Asertivno komunicirati znači obraćati se ostalim sugovornicima sa poštovanjem, a osoba koja asertivno komunicira ne boji se govoriti u svoje ime. Asertivnost karakterizira zastupanje i ostvarivanje vlastitih potreba i interesa, ali ne na agresivan način i ne na štetu drugih osoba. Asertivno ponašanje i komuniciranje je koristan oblik ponašanja jer asertivna osoba dobije ono što želi, uvažavajući pritom druge osobe. Za raliku od asertivnih osoba neasertivne osobe su nejasne u izricanju svojih želja i mišljenja, sramežljive su, niskog su samopoštivanja, a reagiraju povlačenjem i neodlučnošću. Kod asertivnog stila komuniciranja sudionici komunikacije odlučuju koji je njihov stil komuniciranja, planiraju najefikasniji način za dogovor i ponašaju se u skladu sa planom. Asertivna osoba se ponaša na način koji najbolje odgovara toj situaciji [Lamza – Maronić, Glavaš, 2008]. Iz Tablice 1. se vide stilovi komuniciranja.

Tablica 1. Stilovi komuniciranja

Stil komunikacije	Tuđa prava	Moja prava	Sukob
Agresivnost	-	+	+
Pasivnost	+	-	+/-
Asertivnost	+	+	-

Izvor: Lamza – Maronić, Glavaš, 2008., str. 43.

Kod pasivnog stila komuniciranja za raliku od asertivnog ljudi odustaju od svojih prava, ne otkrivaju svoje osjećaje, uvažavaju samo tuđa prava i mišljenja, a prema drugima osjeća ljutnju ili depresiju. Kod agresivnog stila komuniciranja ljudi se zalažu za svoja prava i mišljenja, ali ignoriraju prava i mišljenja drugih. Na taj način agresivni komunikatori stvaraju neprijatelje u svom okruženju. Osoba koja asertivno komunicira se: argumentirano zauzima za sebe na smiren i kulturan način, zna aktivno slušati, poštuje sebe i druge, jasno i konkretno govori, pozitino iskazuje kritiku, preuzima odgovornost za svoje riječi i djela, spremna je izviniti se ako pogriješi, zna se kontrolirati, pokazuje osjećaje, glas i držanje prilagođava situaciji, ostvaruje vlastite potrebe uvažavajući pritom druge osobe, ne ugrožava druge ljude [Lamza – Maronić, Glavaš, 2008].

3. ASERTIVNOST U PRODAJNOM POSLOVANJU

Prodajni menadžment čine menadžeri prodaje na više razina ovisno o veličini poduzeća te prodajni predstavnici koji zajedno čine prodajne timove. Prodajni timovi u prvom redu imaju zadaću zadovoljiti potrebu za prodajom određenih proizvoda i usluga koju je pred njih postavio menadžer prodaje. Kako bi prodajni predstavnici unutar tima ostvarili zadane ciljeve oni kao članovi tima moraju djelovati u međusobnoj interakciji i mora postojati uzajamno povratno djelovanje. Prodajni predstavnik utječe na prodajni tim i prodajni tim utječe na njega [Tudor i Srića, 2014]. Prodajni predstavnici moraju djelovati usklađeno kako bi iskoristili svoju priliku na tržištu. Od presudne je važnosti da je vođa prodajnog tima osoba koja predstavlja pokretačku snagu tima te svojim iskustvom i znanjem pruža oslonac prodajnim predstavnicima u obavljanju prodajnih poslova. Asertivna komunikacija između menadžera prodaje i prodajnih timova te prodajnih predstavnika je izuzetno važna jer ne ostavlja prostora za osobno nezadovoljstvo i frustraciju članova tima zbog nejasno artikuliranih vlastitih stavova i pogleda na dodijeljene zadatke i postavljene ciljeve. Prodajni predstavnik koristeći metode asertivne komunikacije unutar vlastitog tima postavlja temelj za visok stupanj osobne motivacije za uspješnu prodaju.

Asertivnost podrazumijeva samopouzdanost, samosvjesnost i samouvjerenost, a to su osobine koje predstavljaju idealno ponašanje učinkovitog prodajnog predstavnika. Kada svi prodajni predstavnici daju svoj maksimum i jedni druge nadopunjavaju u postizanju prodajnog cilja dolazi do točke u kojoj se postiže maksimalna učinkovitost prodajnog tima. Učinkoviti prodajni tim ima slijedeća obilježja: svi prodajni predstavnici su predani zajedničkom prodajnom cilju; suradnja unutar prodajnog tima je interaktivna, angažirana i međusobno solidarna; kreativnost tima proizlazi iz snažnog timskog duha te podrazumijeva što manje trošenje resursa u dostizanju zadanog cilja; članovi prodajnog tima su ravnopravni što ne isključuje mogućnost osobnog razvoja i isticanja unutar tima; atmosfera unutar prodajnog tima mora biti obilježena entuzijazmom, jakim timskim duhom, osjećajem pripadnosti prodajnom timu te otvorenom i asertivnom komunikacijom. Prodajni timovi koji imaju navedena obilježja iz toga crpe višestruke koristi, a prodajni predstavnici djelujući u okviru prodajnog tima ostvaruju vlastite i timske potrebe te na taj način postižu zadovoljstvo i odgovarajući stupanj motivacije za ostvarenje ciljeva. Pomoću učinkovitih prodajnih timova poduzeće lakše i uspješnije ostvaruje pozitivne rezultate i profitabilno posluje na konkurentnom tržištu.

Prodajna snaga koja proizlazi iz međusobne povezanosti prodajnih timova rezultira kvalitetnijim i višim prodajnim rezultatima nego što bi oni bili kada bi promatrali pojedinačni zbroj rezultata svakog prodajnog tima pojedinačno. Prodajni entuzijazam i timski duh mora biti temelj svakog prodajnog tima jer on razvija kreativnost u prodaji te na taj način donosi dodatnu vrijednost ukupno ostvarenom prodajnom rezultatu. Prodajni procesi moraju biti jasno definirani i učinkoviti kako bi prodajni predstavnici unutar svakog prodajnog tima zadržali visok stupanj motivacije kao ključnog preduvjeta uspješne prodaje [Rijavec, Miljković, 2009]. Asertivna komunikacija se nameće kao temelj izgradnje svih učinkovitih odnosa kako unutar prodajnog tima tako i u izgradnji dugoročno održivog i učinkovitog poslovnog odnosa s kupcima jasno iznoseći vlastite zahtjeve, ali istovremeno i poštujući zahtjeve kupaca. Prodajni predstavnici u cilju izgradnje dugoročno održivog i učinkovitog poslovnog odnosa s kupcem koriste tehnike aktivnog slušanja, prodajnog razgovora i neverbalne komunikacije. Voditelj prodajnog tima odnosno menadžer prodaje određuje razinu komunikacije unutar prodajnog tima između prodajnih predstavnika. Voditelj prodajnog tima ima odgovornost za održavanje dobre atmosfere unutar tima i postizanje odgovarajućeg stupnja profesionalne razine komunikacije između članova prodajnog tima.

Kako bi to postigao voditelj prodajnog tima od svih komunikacijskih vještina najviše mora upotrebljavati vještinu slušanja svojih prodajnih predstavnika. Slušanje je ključno i na temelju njega u međusobnoj interakciji sa članovima svog prodajnog tima voditelj može prikupiti značajan broj korisnih prodajnih informacija koje čine preduvjet za izgradnju učinkovitih i održivih prodajnih odnosa s kupcima poduzeća. Slušanje od voditelja zahtjeva punu pažnju i njegov aktivan pristup procesu slušanja, također on mora i kontrolirati odnosno promišljati svoje odgovore. Kupcu se neverbalnom komunikacijom daje do znanja da ga se aktivno sluša i da se uvažavaju njegovi zahtjevi naglašeni kroz njegovu komunikaciju. Prodajni predstavnik kupca mora gledati u oči, uputiti mu smiješak kada to razgovor zahtjeva, kimati glavom u znak odobravanja i aktivnog slušanja te mora poticati kupca da jasno i nedvojbeno iznese svoje zahtjeve i stavove kako bi dobio kvalitetnu podlogu za uspješnu prodajnu obradu zahtjeva kupca na obostrano zadovoljstvo. Prodajni predstavnik mora biti strpljiv u komunikaciji s kupcem jer svaki kupac na specifičan način iznosi svoje zahtjeve i očekivanja od prodajnog predstavnika odnosno od proizvoda koji mu se nude. Ako prodajnom predstavniku neka činjenica ili zahtjev koji je kupac iznio nije potpuno poznata on mora potaknuti kupca da dodatno pojasni što je želio reći odnosno što od njega očekuje na taj način se između njih uspostavlja i gradi povjerenje i asertivna komunikacija [West, 2005]. Prodajni predstavnik u cilju boljeg razumijevanja i učinkovitije daljnje prodajne obrade zahtjeva kupca mora kontinuirano parafrazirati riječi kupca na način da iznese kupcu sažetak onoga što je aktivno slušao te od njega zatraži potvrdu sažetka slušanja odnosno odobravanje i da se na taj način uvjeri da je razumio ono što mu je kupac iznio. Na taj način se uspostavlja kvalitetno prenošenje poruke između kupca i prodajnog predstavnika kao osnovna svrha njihove međusobne komunikacije. Razgovarajući s kupcem prodajni predstavnik se može udaljiti od same teme prodajnog razgovora s ciljem da razgovarajući o zajedničkim interesima i hobijima uspostavi opušteniju atmosferu razgovora te stekne dodatnu naklonost kupca, ali prodajni predstavnik ne smije iz fokusa izgubiti prodajnu realizaciju kao krajnji cilj prodajnog razgovora s kupcem.

Visoka razina emocionalne inteligencije je poželjna osobina učinkovitog menadžera prodaje, voditelja prodajnog tima i prodajnog predstavnika, jer ona podrazumijeva učinkovito upravljanje prodajnom komunikacijom te uspješnu primjenu elemenata i tehnika asertivne prodaje [Goleman, 2007]. Koliko god atmosfera komunikacije unutar prodaje postane opuštena, ona nikad ne smije dobiti podrugljivu ili napadačku notu sa strane prodajnog predstavnike prema kupcu. Prodajni predstavnik se uvijek treba upitati jer je to što želi reći ključno za ostvarenje prodaje i uspjeha njegovog prodajnog tima, ako nije takvu komunikaciju treba to izbjegavati. Kako bi komunikacija između prodajnog predstavnika i kupca bila učinkovita i dugoročno održiva ona bi se trebala držati slijedećih pravila: komunikacija mora biti iskrena, utemeljena na istinitim činjenicama i podacima; neverbalna komunikacija mora biti u službi poboljšanja verbalne, a ni slučajno suprotno; odnos između prodajnog predstavnika i kupca bez obzira kakva poruka bila mora uvijek sadržavati puno međusobno poštovanje osobnosti; prodajni predstavnik mora biti uvjeren u ono što prezentira kupcu; konfliktne situacije moraju se odmah popravljati, ne smije se dopustiti da eskaliraju; tolerancija i uvažavanje argumenata kupca je nužna; što je moguće više upotrebljavati vlastiti primjer s ciljem uspostave snažnijeg povjerenja između prodajnog predstavnika i kupca [Španjol Marković, 2008].

Prodajni predstavnik pomoću asertivnosti na kupca ostavlja dojam da mu je on najvažniji u trenutku međusobne komunikacije i za to vrijeme komunikacije s kupcem fokus ne smije biti na ni jednog drugog kupca. Prodajni timovi komuniciraju na formalan i neformalan način, formalan način komunikacije je onaj koji treba izgrađivati i na njemu konstantno raditi u cilju povećanja učinkovitosti prodajnog tima. Elementi asertivne prodaje su: jasna i nedvosmislena ponuda kupcu bez skrivenih dijelova; jasna argumentacija cijene i omjera kvalitete proizvoda;

prodajni predstavnik ne smije osjećati strah od kupca bez obzira na ishod prodaje; prodajni predstavnik mora dati kupcu do znanja ako je njegovo ponašanje neprihvatljivo; kupac mora osjećati da se njegovi stavovi uvažavaju, ali i prodajni predstavnik brani svoje stavove; prodajni predstavnik jasno kupcu daje do znanja što može očekivati od ponuđenih proizvoda i usluga ako se za njih odluči. Pomoću elemenata asertivne prodaje prodajni predstavnici uspijevaju zadržati visoku razinu učinkovitosti prodaje iako se suočavaju s velikim brojem različitih mišljenja, stavova i temperamenata kupaca. Uz pomoć asertivnosti prodajni predstavnici u prodajnim odnosima s kupcima zadržavaju svoje dostojanstvo i motivaciju jer kupci cijene jasan i transparentan odnos bez skrivenih namjera.

Najznačajnije asertivne tehnike prodaje su: ponavljanje ponude kupcu koji ju ne razumije ili ne želi pokazati da ju razumije nekoliko puta dok kupac ne potvrdi da je razumio što mu se nudi; prodajni predstavnik na temelju vlastitih osjećaja i stavova kupcu prezentira ponudu, ali uvažava i njegove. U slučaju neprihvaćanja ponude od strane kupca prodajni predstavnik ne napada kupca već uvažava njegove argumente i razloge zbog kojih mu je ponuda neprihvatljiva. Odbijanje kupca iz nekog razloga nije neuspjeh ako su svi koraci asertivne prodaje zadovoljeni tek korak u smjeru nove uspješne prodaje [Rouse, Rouse, 2005].

Klima koja vlada unutar prodajnog tima direktno utječe na pojedinačne rezultate prodajnih predstavnika, ona mora biti pozitivna, a neformalna komunikacija unutar tima se mora uvažavati od strane svih članova tima. Sve nedoumice i poteškoće s kojima se članovi prodajnog tima susreću na zajedničkim sastancima sa voditeljem prodaje se analiziraju i nude se najbolja rješenja za njihovo prevladavanje. Na sastancima se putem tablica i prezentacija jasno prezentiraju zahtjevi koje voditelj očekuje od prodajnih predstavnika, ali isto tako i prodajni predstavnici prezentiraju zahtjeve svojih kupaca koji se od njih očekuju. Upravo ovakvom dvosmjernom komunikacijom i brzim protokom i obradom informacijama unutar tima i između tima i kupca stvaraju se preduvjeti za prodajnu učinkovitost. Jedan od ključnih alata prodajnog predstavnika je prodajna komunikacija odnosno govor dok asertivnost slušanje stavlja u prvi plan ispred govora, međutim aktivno slušajući kupca i njegove zahtjeve prodajni predstavnik govori jasnije i konkretnije te ne gubi energiju i vrijeme na izgovaranje velikog broja riječi koje nemaju utjecaja na prodajni rezultat. Asertivnost se povezuje s djelovanjem u timu upravo kroz komunikaciju jer komunicirajući unutar tima svi članovi prodajnog tima žele se osjećati ravnopravno na istoj razini s ostalim članovima ni iznad ni ispod njih. Na taj način svi članovi prodajnog tima mogu iskreno iznositi svoje mišljenje i stavove osjećajući suosjećanje i zainteresiranost njihovih kolega za ono što govore. Kako bi se prodajni tim posložio na najbolji mogući način i kako bi njegovo prodajno djelovanje bilo maksimalno učinkovito potrebno je određeno vrijeme kako bi se svi odnosi unutar tima postavili u idealne korelacije od strane voditelja prodajnog tima i menadžera prodaje. Ne postoji određena formula po kojoj se može izračunati predviđeno vrijeme potrebno za to jer ono ovisi o velikom broju varijabli i čimbenika kako iskustvenih tako i karakternim osobinama svakog pojedinog člana prodajnog tima [Fox, 2006].

4. METODOLOGIJA I REZULTATI ISTRAŽIVANJA

Za potrebne rada je provedeno istraživanje putem anketnog upitnika sa 15 pitanja. Prvi dio pitanja je vezan uz demografske karakteristike ispitanika: dob, spol i stručnu spremu. Drugi dio pitanja je vezan uz poznavanje i uporabu asertivnosti kao prodajne tehnike, a pitanja su bila zatvorenog tipa sa ponuđenim odgovorima. Autori rada su kreirali anketni upitnik za potrebe istraživanja ovog rada, a polazište za postavljena pitanja je poslovna praksa. Istraživanje je

provedeno putem Google obrasca te su ispitanici u uvodnom djelu bili upoznati sa svrhom istraživanja. Istraživanje je bilo provedeno od 03.02. – 05.03.2023. godine, a u njemu je sudjelovalo 66 ispitanika koji su zaposleni na poslovima prodaje u trgovinskim poduzećima. Cilj istraživanja je bio utvrditi koliko ispitanika poznaje i koristi tehnike asertivnog komuniciranja u prodaji. Rezultati istraživanja su analizirani deskriptivnom statistikom.
U skladu se teorijsko-metodološkim pristupom postavljaja se hipoteza:
H_1 – Ispitanici koriste tehnike asertivne komunikacije na svojim poslovima prodaje.

U istraživanju je sudjelovalo 40,9 % ispitanika u dobi od 36- 45 godina, 28,8 % u dobi od 26 – 35 godina, 16,7 % ispitanika u dobi od 46- 55 godina, 9, 1 % u dobi od 18 – 25 godina i 4,5 % u dobi od 56 – 65 godina. Ispitanici su 60, 6 % ženskog spola, a 39,4 % muškog. Ispitanici su po stručnoj spremi: 57,6 % ispitanika ima završenu srednju školu, 21,2 % sveučilišni studij, 19,7 % stručni studij, 1,5 % završen doktorski studij. 45,5 % ispitanika je po zanimanju trgovac, 19,7 % voditelj prodaje, 15,2 % prodajni predstavnik, 9,1 % voditelj ključnih kupaca, 9,1 % menadžer prodaje i 1,5 % unaprjeđivač prodaje.

Ispitanici poznaju pojam asertivnosti kao komunikacijske vještine (njih 63,6 %), a 60,6 % ispitanika koristi asertivnu tehniku kada žele ostvariti ciljeve. Ispitanici u svakodnevnoj poslovnoj komunikaciji koriste asertivnost ovisno o situaciji (njih 60,6 %), 27,3 % ispitanika je koriste uvijek sa svakim sugovornikom i u svakoj situaciji, a 12,1 % je koristi ovisno od sugovornika. Ispitanici koriste asertivnost u komunikaciji i sa kolegama i sa kupcima (njih 69,7 %), 22,7 % u komunikaciji sa kupcima, a 7,6 % ispitanika koristi asertivnost samo u komunikaciji sa kolegama. Što se tiče vrste tehnika; 33,3 % ispitanika koristi asertivnu tehniku „pokvarena ploča“, 30,3 % koristi priznanje i davanje pohvala, 16,6 % koristi izricanje i primanje kritike, 7,6 % koristi „zatraži vijeme i daj ga drugima“, 7,6 % koristi „kako reći ne drugima“, a 4,5 % koristi „ja poruke“. Ispitanike zanima što sugovornici u poslovnoj komunikaciji govore i slušaju sugovornika (98,5 %), a 1,5 % ispitanika ne sluša sugovornika. Ispitanici smatraju da koristeći asertivne tehnike prodaje su uspješniji na svom radnom mjestu (njih 83,3 %). Ispitanici prepoznaju kod sugovornika 34,8 % asertivno ponašanje, 31,8 % pasivno-agresivno ponašanje, 21,2 % pasivno ponašanje, 12,1 % ispitanika prepoznaje agresivno ponašanje svojih sugovornika. Ispitanici se žele dalje educirati vezano uz primjenu asertivnih tehnika u prodajnom procesu (62,1 %). Ispitanici su se upoznali sa asertivnim načinom komuniciranja; 57,6 % ispitanika se upoznalo sa asertivnossću samoeduciranjem, 19,7 % putem internih edukacija u poduzeću, 13,6 % putem vanjskih edukacija, 6,1 % od strane svojih nadređenih, a 3 % od svojih kolega. Ispitanici koriste riječ „hvala“ u svakodnevnoj poslovnoj komunikaciji (98 %). S obzirom na rezultate istraživanje hipoteza (H_1 – Ispitanici koriste tehnike asertivne komunikacije na svojim poslovima prodaje) se prihvaća.

5. ZAKLJUČAK

Prodaja počiva na izgradnji odnosa kako međusobnih između članova prodajnog tima tako i odnosa prodajnih timova s kupcima, a asertivnost pomoću svojih elemenata i tehnika asertivne prodaje pruža snažnu podršku za izgradnju dugoročno održivih i učinkovitih poslovnih odnosa. Asertivnost kao tehnika prodaje donosi prednosti izgradnje dugoročno održivih odnosa s kupcima jer se temelje na međusobnom uvažavanju i povjerenju koje jamči učinkovitu prodaju održivu na dugi rok. Asertivnost zahtjeva kontinuiranu edukaciju prodajnih predstavnika kako bi zadržali visoki stupanj profesionalnosti i razine komunikacije, ali bez asertivnih tehnika prodaje odnosi koji se uspostavljaju s kupcima su manje učinkoviti i kraćeg su vijeka trajanja. Trgovinska poduzeća koja žele biti uspješna moraju usvojiti asertivnost kao ključnu prodajnu

tehniku te ju moraju implementirati na razini cjelokupnog prodajnog menadžmenta od prodajnih menadžera, voditelja prodaje, supervizora, prodajnih predstavnika, unapređivača prodaje i prodavača. Kada trgovinsko poduzeće implementira asertivnost u ukupnom prodajnom menadžmentu može se reći da su se stvorili uvjeti za ostvarenje učinkovitih i dugoročno održivih prodajnih rezultata poduzeća.

Rezultati istraživanja provedenog za potrebe rada u cilju uvida koliko djelatnici na poslovima prodaje koriste asertivne tehnike u komunikaciji ukazuju da su ispitanici upoznati sa pojmom i asertivnom komunikacijom koju koriste u svom poslovnom procesu (60,6 % ispitanika svakodnevno koristi asertivne tehnike). Ispitanici koriste različite tehnike asertivne komunikacije i žele se dalje educirati za njihovu primjenu u poslovnom okruženju. S obzirom na rezultate istraživanje hipoteza (H_1 – Ispitanici koriste tehnike asertivne komunikacije na svojim poslovima prodaje) se prihvaća.

Ograničenje u istraživanju je bio uzorak odnosno poteškoće u prikupljanju informacija. Preporuke za buduća istraživanja mogu biti primjena asertivnih tehnika u drugim granama gospodarstva npr. u turizmu i ugostiteljstvu.

Benedikt Kotruljević u svom djelu „O trgovini i savršenom trgovcu“ kaže za trgovca: „Mora biti svestran i znati se ophoditi sa narodom svake ruke, velikim i malim. Ne smije biti protivan, osvetljiv, bezobrazan i nastran, a ni sljepar, tašt, rasipan, brutalan, izjelica ni popilica. Najzad, sve mane koje su nekima dopuštene trgovcu se nigdje ne dolikuju. Prvo mora biti razgovorljiv i komunikativan sa svojima, ali i sa zlima mora biti ljubazan i dobroćudan, blaga i prijatna lica. Prijazan mora biti sa svakim. U prodavaonici treba dočekati kupca onako kao što kulturan čovjek dočekuje dragoga gosta u svome domu.“

REFERENCE

[1] Borovac Zekan, S., Gabrić, K. (2022). Neverbalna komunikacija kao alat uvjeravanja u javnom nastupu., Zbornik radova Veleučilišta u Šibeniku, Vol 15, No 3-4, Šibenik, Hrvatska.

[2] Fox, R. (2006). *Poslovna komunikacija*. Hrvatska sveučilišna naklada, Zagreb, Hrvatska.

[3] Goleman, D. (2007). *Emocionalna inteligencija u poslu*. Mozaik knjiga, Zagreb, Hrvatska.

[4] Lamza – Maronić, M., Glavaš, J. (2008). *Poslovno komuniciranje*. Ekonomski fakultet u Osijeku, Osijek, Hrvatska

[5] Lehrer, J. (2012). *Proust je bio neuroznanstvenik*. Algoritam, Zagreb, Hrvatska.

[6] Luhman N. (1972). *Funktionen und Folgen formaler Organization*. Duncker & Humblot, Berlin, Njemačka.

[7] Mehrabian, A. (2017). *Nonverbal Communication*. Routledge, New York, SAD.

[8] Parsons, T. (1966). *The social system*. Routledge, New York, SAD.

[9] Rijavec, M., Miljković, D. (2009). *Pozitivna psihologija na poslu*. IEP – D2, Zagreb, Hrvatska.

[10] Rouse, M. J., Rouse, S. (2005). *Poslovne komunikacije: kulturološki i strateški pristup*. Masmedia, Zagreb, Hrvatska.

[11] Španjol Marković, M. (2008). *Moć uvjeravanja (Govorništvo za menadžere i one koji to žele postati).* Profil International d.o.o., Zagreb, Hrvatska.

[12] Watzslavick, P. (1976). *Wie wirklich ist die Wirklichet?*. Wahn-Verstehen, Munchen, Njemačka.

[13] West, M., Ipša, I. (2005). *Tajne uspješnog upravljanja timom.* Školska knjiga, Zagreb, Hrvatska.

https://crodma.hr/