

**11th International
Scientific Conference**

CRODMA 2026

Book of Papers



11th International Scientific Conference CRODMA 2026

BOOK OF PAPERS

October 22-23, 2026

University of Zagreb
Faculty of Organization and Informatics

Varaždin, Croatia

11th International Scientific Conference (CRODMA 2026), Book of Papers. Copyright 2026. 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

Franjevački trg 11, 42000 Varaždin, Croatia

For the publisher

Iva Gregurec - President of Croatian Direct Marketing Association

Editors

Iva Gregurec (Editor-in-Chief)

University of Zagreb, Faculty of Organization and Informatics, Croatia

Zrinka Lacković Vincek

University of Zagreb, Faculty of Organization and Informatics, Croatia

Miha Marič

University of Maribor, Faculty of Organisational Sciences, Slovenia

Matea Matić Šošić

University of Dubrovnik, Faculty of Economics and Business, Croatia

Technical Editor

Ladislav Cvetko

University of Zagreb, Faculty of Organization and Informatics, Croatia

ISSN 2459-7953

Editors disclaim responsibility for language errors.

11th International Scientific Conference CRODMA 2026

CONFERENCE CO-ORGANIZERS:



Fakultet ekonomije i turizma
"Dr. Mijo Mirković"



Sveučilište u Zadru
Universitas Studiorum
Jadertina | 1396 | 2002 |



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.



RECENZENTI

11. Međunarodne znanstvene konferencije – CRODMA 2026. /

REVIEWERS of the 11th International Scientific Conference – CRODMA 2026

Aleksić Fredotović, Ana; University of Zagreb, Faculty of Economics and Business, Croatia

Benazić, Dragan; Juraj Dobrila University of Pula, Faculty of Economics and Tourism "Dr. Mijo Mirković, Croatia

Bevanda, Arnela; University of Mostar, Faculty of Economics, Bosnia and Hercegovina

Biloš, Antun; University J. J. Strossmayer of Osijek, Faculty of Economics and Business, Croatia

Budimir, Bruno; University J. J. Strossmayer of Osijek, Faculty of Economics and Business, Croatia

Čuić Tanković, Ana; University of Rijeka, Faculty of Tourism and Hospitality Management, Croatia

Čutura, Marija; University of Mostar, Faculty of Economics, Bosnia and Hercegovina

Detelj, Kristina; University of Zagreb, Faculty of Organization and Informatics, Croatia

Dlačić, Jasmina; University of Rijeka, Faculty of Economics and Business, Croatia

Dragičević, Marija; University of Dubrovnik, Faculty of Economics and Business, Croatia

Dvorski, Lacković Ivana; University of Zagreb, Faculty of Organization and Informatics, Croatia

Đunđek, Ivana; University of Zagreb, Faculty of Organization and Informatics, Croatia

First Komen, Ivana; University of Rijeka, Faculty of Economics and Business, Croatia

Grd, Petra; University of Zagreb, Faculty of Organization and Informatics, Croatia

Ham, Marija; University J. J. Strossmayer of Osijek, Faculty of Economics and Business, Croatia

Has, Adela; University J. J. Strossmayer of Osijek, Faculty of Economics and Business, Croatia

Horvat, Sandra; University of Zagreb, Faculty of Economics and Business, Croatia

Hrustek, Larisa; University of Zagreb, Faculty of Organization and Informatics, Croatia

Jelčić, Sandra; University of Mostar, Faculty of Economics, Bosnia and Hercegovina

Kadoić, Nikola; University of Zagreb, Faculty of Organization and Informatics, Croatia

Krajnović, Aleksandra; University of Zadar, Department of Economics, Croatia

Križman, Danijela; Juraj Dobrila University of Pula, Faculty of Economics and Tourism "Dr. Mijo Mirković, Croatia

Krupka, Zoran; University of Zagreb, Faculty of Economics and Business, Croatia

Letica, Maja; University of Mostar, Faculty of Economics, Bosnia and Hercegovina

Luković, Ivan; University of Belgrade, Faculty of Organizational Sciences, Serbia

Mandić, Miroslav; University of Zagreb, Faculty of Economics and Business, Croatia

Marič, Miha; University of Maribor, Faculty of Organizational Sciences, Slovenia

Maršić, Kristina; University of Zagreb, Faculty of Textile Technology, Croatia

Matić Šošić, Matea; University of Dubrovnik, Faculty of Economics and Business, Croatia

Okreša Đurić, Bogdan; University of Zagreb, Faculty of Organization and Informatics, Croatia

Oreški, Dijana; University of Zagreb, Faculty of Organization and Informatics, Croatia

Pandža Bajs, Irena; University of Zagreb, Faculty of Economics and Business, Croatia

Perišić Prodan, Marina; University of Rijeka, Faculty of Tourism and Hospitality Management, Croatia

Pihir, Igor; University of Zagreb, Faculty of Organization and Informatics, Croatia

Plantak Vukovac, Dijana; University of Zagreb, Faculty of Organization and Informatics, Croatia

Rončević, Ante; University North, Croatia

Ružić, Erik; Juraj Dobrila University of Pula, Faculty of Economics and Tourism "Dr. Mijo Mirković, Croatia

Sesar, Vesna; University North, Croatia

Sinčić, Dubravka; University of Zagreb, Faculty of Economics and Business, Croatia

Stančin, Kristian; University of Rijeka, Faculty of Informatics and Digital Technologies, Croatia

Šebalj, Dario; University J. J. Strossmayer of Osijek, Faculty of Economics and Business, Croatia

Škare, Vatroslav; University of Zagreb, Faculty of Economics and Business, Croatia

Turkalj, Davorin; University J. J. Strossmayer of Osijek, Faculty of Economics and Business, Croatia

Vlahek, Dino; University of Zagreb, Faculty of Organization and Informatics, Croatia

Vrdoljak Raguž, Ivona; University of Dubrovnik, Faculty of Economics and Business, Croatia

Vuković, Dijana; University North, Croatia



PROGRAMSKI ODBOR

11. Međunarodne znanstvene konferencije – CRODMA 2026. /

PROGRAM COMMITTEE of the

11th International Scientific Conference – CRODMA 2026

Gregurec, Iva; University of Zagreb, Faculty of Organization and Informatics, Croatia - **Chair**

Dobrinić, Damir; University of Zagreb, Faculty of Organization and Informatics, Croatia - **Honorary Chair**

Bajramović, Dženis; University of Novi Pazar, Serbia

Bašan, Lorena; University of Rijeka, Faculty of Tourism and Hospitality Management, Croatia

Begičević Ređep, Nina; University of Zagreb, Faculty of Organization and Informatics, Croatia

Benitez Burgos, Alexandra; Amsterdam University of Applied Sciences, Faculty of Business and Economics, Netherlands

Bevanda, Arnela; University of Mostar, Faculty of Economics, Bosnia and Herzegovina

Bijakšić, Sanja; University of Mostar, Faculty of Economics, Bosnia and Herzegovina

Biloš, Antun; University J. J. Strossmayer of Osijek, Faculty of Economics and Business, Croatia

Ciunova-Shuleska, Anita; Ss. Cyril and Methodius University in Skopje, Faculty of Economics, North Macedonia

Čater, Barbara; University of Ljubljana, School of Economics and Business, Slovenia

Dlačić, Jasmina; University of Rijeka, Faculty of Economics and Business, Croatia

Grd, Petra; University of Zagreb, Faculty of Organization and Informatics, Croatia

Horváth, Dóra; Corvinus University of Budapest, Department of Marketing and Design Communications, Hungary

Horzelski, Wojciech; University of Łódź, Faculty of Mathematics and Computer Science, Poland

Keglević Kozjak, Suzana; University of Zagreb, Faculty of Organization and Informatics, Croatia

Kelić, Ivan; University J. J. Strossmayer of Osijek, Faculty of Economics and Business, Croatia

Kovšca, Vladimir; University of Zagreb, Faculty of Organization and Informatics, Croatia

Krajnović, Aleksandra; University of Zadar, Department of Economics, Croatia

Križman, Danijela; Juraj Dobrila University of Pula, Faculty of Economics and Tourism „Dr. Mijo Mirković“, Croatia

Krupka, Zoran; University of Zagreb, Faculty of Economics and Business, Croatia

Lacković Vincek, Zrinka; University of Zagreb, Faculty of Organization and Informatics, Croatia

Mandić, Miroslav; University of Zagreb, Faculty of Economics and Business, Croatia

Marič, Miha; University of Maribor, Faculty of Organizational Sciences, Slovenia

Matić Šošić, Matea; University of Dubrovnik, Faculty of Economics and Business, Croatia

Melović, Boban; University of Montenegro, Faculty of Economics, Montenegro

Mrvica Mađarac, Sandra; University of Applied Sciences “Lavoslav Ružička” in Vukovar, Croatia

Ozuem, Wilson; University of Cumbria, Institute of Business, Industry and Leadership, UK

Pavičić, Jurica; University of Zagreb, Faculty of Economics and Business, Croatia

Pavlić, Ivana; University of Dubrovnik, Faculty of Economics and Business, Croatia

Perković, Sonja; Aarhus University, Department of Management, Denmark

Peštek, Almir; University of Mostar, Faculty of Economics, Bosnia and Herzegovina

Pihir, Igor; University of Zagreb, Faculty of Organization and Informatics, Croatia

Rabuzin, Kornelije; University of Zagreb, Faculty of Organization and Informatics, Croatia

Rončević, Ante; University North, Croatia

Ružić, Erik; Juraj Dobrila University of Pula, Faculty of Economics and Tourism „Dr. Mijo Mirković“, Croatia

Staneva, Krasimira; Varna University of Management, Bulgaria

Sudarić, Željko; University of Applied Sciences “Lavoslav Ružička” in Vukovar, Croatia

Sukić, Enes; University Union, Faculty of Information Technology and Engineering, Serbia

Tihić, Mirza; Syracuse University, Whitman School of Management, Department of Entrepreneurship and Emerging Enterprises, USA

Tomašević Lišanin, Marija; University of Zagreb, Faculty of Economics and Business, Croatia

Tomičić Furjan, Martina; University of Zagreb, Faculty of Organization and Informatics, Croatia

Tomičić-Pupek, Katarina; University of Zagreb, Faculty of Organization and Informatics, Croatia

Turkalj, Davorin; University J. J. Strossmayer of Osijek, Faculty of Economics and Business, Croatia

Vlastelica, Tamara; University of Belgrade, Faculty of Organizational Sciences, Serbia

Vlašić, Goran; University of Zagreb, Faculty of Economics and Business, Croatia



ORGANIZACIJSKI ODBOR

11. Međunarodne znanstvene konferencije – CRODMA 2026. /

ORGANIZING COMMITTEE of the

11th International Scientific Conference – CRODMA 2026

Lacković Vincek, Zrinka; University of Zagreb, Faculty of Organization and Informatics, Croatia - **Chair**

Hrustek, Larisa; University of Zagreb, Faculty of Organization and Informatics, Croatia - **Secretary**

Kutnjak, Ana; University of Zagreb, Faculty of Organization and Informatics, Croatia

Kuštelega, Magdalena; University of Zagreb, Faculty of Organization and Informatics, Croatia

Cvetko, Ladislav; University of Zagreb, Faculty of Organization and Informatics, Croatia

Oletić Tušek, Izabela; University of Zagreb, Faculty of Organization and Informatics, Croatia

Službeni e-mail / Official e-mail: **info@crodma.hr**

CONTENTS

WHEN PERCEIVED AI FAMILIARITY IS NOT ENOUGH: BENEFITS AND EMOTIONS IN EXPLAINING AI TRUST

ANTUN BILOŠ

1

CAN GENAI SUPPORT BUSINESS MODEL INNOVATION IN THE CONTEXT OF DIGITAL TRANSFORMATION? A MULTIPLE-CASE STUDY OF TWO SMES

MATIJA ŠAJN

13

VIDEO MARKETING'S DECADE OF GROWTH AND WHY AI MAKES HUMAN STORYTELLING MORE VALUABLE

ČRTOMIR RASPOR JOSIPOVIČ, MIHA MARIČ

27

AWARENESS OF FASHION CONSUMPTION CONSEQUENCES AND SUSTAINABLE CLOTHING PRACTICES

LARISA HRUSTEK, ANA KUTNJAK, KRISTINA MARŠIĆ

37

DIGITAL AGE DECEPTION: THE ROLE OF AI IN DISINFORMATION DETECTION

LUKA VIDAK, RENATA MEKOVEC

57

KONCEPTUALNI MODEL DIGITALNE TRANSFORMACIJE PROCESA IZRADE B2B PONUDA OSIGURANJA

SUZANA KEGLEVIĆ KOZJAK, TANJA ŠESTANJ-PERIĆ, IVANA ĐURDEK

69

FINFLUENCERI I FINANCIJSKE PORUKE NA DRUŠTVENIM MREŽAMA: EKSPLOLATIVNA ANALIZA SADRŽAJA U HRVATSKOM DIGITALNOM PROSTORU

TONČI SVILOKOS, ANTE ZDILAR, MERI ŠUMAN TOLIĆ

79

INSIGHTS ON AWARENESS OF SUSTAINABLE ENERGY CONSUMPTION

VANESA GUDIĆ, MAJA KUNŠTEK, NIKOLINA TUMPAK, MARTINA TOMIČIĆ FURJAN

91

**MARKETINŠKA KOMUNIKACIJA ODABRANIH HOTELSKIH PODUZEĆA NA DRUŠTVENIM MREŽAMA:
KOMPARATIVNA ANALIZA FACEBOOKA, INSTAGRAMA I TIKTOKA**

LUCIA STARČIĆ, JASMINA DLAČIĆ, KRISTINA ČRNJAR, JANA PLIŠKO

103

**ONLINE PRODAJA KAO POKAZATELJ MEĐUNARODNE TRŽIŠNE ORIJENTACIJE HRVATSKIH MIKRO,
MALIH I SREDNJIH PODUZEĆA U PRERAĐIVAČKOJ INDUSTRIJI**

KLARA ŠILEC, ZRINKA LACKOVIĆ VINCEK, VLADIMIR KOVŠKA

117

**PERCIPIRANI RIZIK I INFORMACIJSKI ELEMENTI U ONLINE KUPNJI PARFEMA: EMPIRIJSKA ANALIZA
POTROŠAČKOG ODLUČIVANJA**

LORENA LONGIN, BILJANA MARKOVIĆ, JELENA BLAŽI

133

**DIGITALNI MARKETING LOKALNE HRANE I RURALNOG TURIZMA: UTJECAJ AUTENTIČNOSTI,
SLJEDIVOSTI I KORISNIČKOG ISKUSTVA NA NAMJERU KUPNJE**

DAMIR MIHANOVIĆ, ANITA PAMUKOVIĆ, EMILIJA FRIGANOVIĆ

145

OD INOVACIJE DO REGULACIJE: BNPL I DIREKTIVA (EU) 2023/2225

TONI POŽEGA, NORA BALIĆ

157

**MARKET ENTRY AND BRAND POSITIONING STRATEGIES IN THE PLANT-BASED FOOD SECTOR: A
COMPARATIVE ANALYSIS OF GLOBAL LEADERS AND EMERGING MARKET PLAYERS**

MILOŠ MILOVANČEVIĆ, PETRA KARANIKIĆ, BARBARA PUH

171

**TEXT OR VOICE? A CONCEPTUAL FRAMEWORK FOR MULTIMODAL AI SALES ASSISTANCE AND ITS
EFFECTS ON PURCHASE DECISION-MAKING, TRUST, AND USER EXPERIENCE IN SPECIALIZED
E-COMMERCE**

TILEN MATJAŠIČ, ROBERT LESKOVAR

181

**PODUZETNIČKI MARKETING U DIGITALNOM DOBU: TEORIJSKI PREGLED I ILUSTRATIVNI PRIMJERI IZ
POLJSKE I HRVATSKE**

ANTE RONČEVIĆ, DANIJELA MAGDALENIĆ

193

**EMPLOYER BRANDING AS A STRATEGIC MARKETING TOOL FOR TALENT ATTRACTION AND
EMPLOYEE ENGAGEMENT IN THE DIGITAL ENVIRONMENT**

NINA MINOV, MIHA MARIČ

205

TROVANJE PODATAKA U ETL PROCESIMA POSLOVNE INTELIGENCIJE

MAJA CERJAN, KORNELIJE RABUZIN, DUNJA VIŠNJIĆ

215

**USPOREDNA ANALIZA DIMENZIJA RAVNOTEŽE PRIVATNOG I POSLOVNOG ŽIVOTA PREMA
OBILJEŽJIMA ZAPOSLENIKA**

NIKOLINA TUMPAK, LORENA PIKL

231

OD NESTAŠICE DO ODRŽIVOSTI: EVOLUCIJA KONCEPTA DEMARKETINGA

MAGDALENA KUŠTELEGA, IVA GREGUREC, MATEA MATIĆ ŠOŠIĆ

243

WHEN PERCEIVED AI FAMILIARITY IS NOT ENOUGH: BENEFITS AND EMOTIONS IN EXPLAINING AI TRUST

ANTUN BILOŠ

Faculty of Economics and Business in Osijek
Josip Juraj Strossmayer University of Osijek
Trg Ljudevita Gaja 7, 31000 Osijek, Croatia
antun.bilos@efos.hr

ABSTRACT

Trust in artificial intelligence (AI) may differ with perceived familiarity, usage experience, expected benefits, risks and emotional responses. This paper examines overall and domain-specific AI trust using survey data from 411 Croatian internet users. The four domains are healthcare, security, recommender systems and human resources. Hierarchical regression models use data from 351 respondents with complete data on the full predictor set and within the demographic coding. Demographic and status variables explain 8.6% of the variance in overall trust. Adding perceived AI familiarity and AI use in work or study raises this to 24.3%. In the full model, which explains 47.6% of the variance, perceived benefits and positive emotions have the largest standardized coefficients, while familiarity and use are no longer significant. Familiarity groups differ significantly in overall trust and trust in healthcare, security and recommender systems, but not in human resources. Familiarity represents respondents' self-assessments rather than objectively demonstrated AI knowledge. The findings support examining experience, evaluations and emotions jointly, while the cross-sectional design precludes causal or mediation conclusions.

KEYWORDS: artificial intelligence, AI trust, perceived AI familiarity, AI use, perceived benefits, emotions, digital consumers, human resources, Croatia, internet users

1. INTRODUCTION

Artificial intelligence is increasingly embedded in everyday digital services. Internet users encounter AI through search engines, recommender systems, translation tools, customer support, navigation, financial services, healthcare applications and generative AI systems. As AI becomes more visible and accessible, public attitudes toward AI are becoming relevant for organizations, researchers and policy makers. Trust is central to understanding how people evaluate AI and their willingness to rely on AI-supported decisions. Recent global evidence shows widespread AI use alongside limited trust and concern about AI risks (Gillespie et al., 2025). The study also links trust with AI literacy, perceived benefits, risks and institutional safeguards. Croatia was not included, so these findings provide international context rather than a direct national benchmark.

Trust in AI is a complex construct. It is related to perceived system performance, reliability, transparency, fairness and the purpose for which AI is used (Glikson & Woolley, 2020; Kaplan et al., 2023; Lockey et al., 2021). User characteristics and application context are also relevant (Yang & Wibowo, 2022). The same person may be relatively comfortable with AI-based recommendations in shopping or travel planning, but more cautious about AI involvement in healthcare, security or human resources decisions.

A common assumption is that people who feel more familiar with AI or use it more often will also trust it more. However, perceived familiarity is a subjective assessment and cannot establish what a person actually knows about AI. Familiarity and use may also have different associations across applications. Horowitz et al. (2024) report that familiarity is associated with greater support for some autonomous technologies, while responses are less favourable when automation concerns tasks respondents themselves perform. Evaluations of benefits and risks, together with emotional responses, provide further reasons to examine trust beyond familiarity alone (Kreps et al., 2023).

This paper examines these issues using data from Croatian internet users. It has three aims: to describe overall trust and trust in healthcare, security, recommender systems and human resources; to examine differences between perceived familiarity groups; and to assess whether familiarity, AI use, benefits, risks and emotions add explanatory value beyond demographic and status variables. Its exploratory contribution is to consider these self-reported experiences and evaluations jointly while retaining attention to application context. The analysis distinguishes feeling familiar with AI from demonstrated knowledge and examines whether familiarity remains associated with trust when benefits and emotions are considered.

2. LITERATURE REVIEW

2.1. TRUST IN AI AND DOMAIN SENSITIVITY

Trust is a central concept in research on human interaction with AI. It commonly concerns willingness to accept vulnerability based on positive expectations about a system and its use (Gillespie et al., 2025; Glikson & Woolley, 2020). Research considers system characteristics, user characteristics and application context. Reviews emphasize perceived performance and reliability alongside transparency and other features of human–AI interaction (Glikson & Woolley, 2020). Conceptual work also distinguishes trust from technical reliability and raises questions about appropriate expectations and responsibility when using AI (Jacovi et al., 2021; Ryan, 2020). Transparency is a further consideration in empirical research on AI trust (Schmidt et al., 2020).

A broad view of AI trust is useful, but it can hide differences between application domains. AI-supported decisions differ in perceived stakes, reversibility, personal consequences and opportunities for human oversight. Araujo et al. (2020) examine evaluations of automated decision-making across media, health and legal scenarios. Research on travel recommendation systems and healthcare AI also connects trust with application-specific perceptions of benefits and risks (Kerstan et al., 2024; Shi et al., 2021).

In the Croatian context, Biloš and Budimir (2023) found that internet users generally expressed higher trust in humans assisted by AI than in AI alone. This finding highlights the relevance of the role assigned to AI within a decision. The global study by Gillespie et al. (2025) also reports

variation in trust across AI applications. The present study therefore examines trust across four domains and an overall score summarizing trust in these applications.

2.2. FAMILIARITY, AI USE, BENEFITS AND RISKS

Perceived AI familiarity, objective knowledge and AI literacy should be distinguished. Familiarity concerns how informed people feel, whereas demonstrated knowledge requires assessment beyond self-report. Research on AI literacy addresses broader competencies and their measurement (Wang et al., 2023), and pilot research examines literacy in relation to trust in practical scenarios (Huang & Ball, 2024). These constructs should not be treated as interchangeable. Horowitz et al. (2024) further show that familiarity with technology and familiarity with the tasks being automated can have different associations with support for autonomous applications.

Frequency of AI use is related to familiarity, but the two constructs are not identical. A person may feel familiar with AI without using it often, while another may use AI frequently for a narrow set of tasks. Repeated use offers opportunities to encounter both benefits and weaknesses. Trust may also be relevant to whether people choose to use AI. It is therefore useful to examine perceived familiarity and self-reported use separately, without assuming a single direction of association (Gillespie et al., 2025; Horowitz et al., 2024).

Perceived benefits and risks represent another part of AI evaluation. Benefits may include efficiency, convenience, decision support or reduced effort. Risks may include inaccurate outputs, discrimination, privacy loss or unclear accountability. Kreps et al. (2023) discuss the AI “trust paradox”, in which support for AI use can exceed expressed trust. Their findings connect support with assessments of benefits and risks, efficiency beliefs and optimism. Ding et al. (2026) also consider the coexistence of trust and risk awareness. In the global study by Gillespie et al. (2025), expected benefits have a stronger positive association with trust than risk concern has a negative association. These findings suggest that concern and favourable evaluations need to be considered together rather than treated as opposite ends of one attitude.

2.3. EMOTIONAL RESPONSES AND AI TRUST

Emotional responses offer a further perspective on AI trust. People may feel optimistic, excited or relaxed, while also feeling worried, afraid or angry. Optimism is relevant to research on support for AI use alongside perceived benefits (Kreps et al., 2023). Negative emotions may accompany concerns about control, privacy or the consequences of automation, yet fear does not necessarily rule out adoption (Cugurullo & Acheampong, 2024). Research on technology self-efficacy, trust propensity, fear and AI acceptance also indicates that these responses are related in complex ways (Montag et al., 2023). Positive and negative emotions therefore merit separate consideration.

In this paper, emotional responses are examined alongside demographics, perceived familiarity, AI use, benefits and risks. This allows an assessment of their additional associations with trust. Expected benefits concern anticipated outcomes, while emotions concern feelings about AI, but both may share a broader favourable evaluation of the technology. Their inclusion as separate predictors does not itself establish that they are distinct causal mechanisms. For digital marketing and service contexts, the question is whether these evaluations and feelings help explain variation in trust beyond familiarity and reported use.

3. METHODOLOGY

3.1. RESEARCH DESIGN AND SAMPLE

The study is based on a self-administered internet survey conducted among Croatian internet users in June 2025 using the Alchemer survey platform. The questionnaire was developed as a partial adaptation of the global research framework on trust, attitudes and use of AI (Gillespie et al., 2023), with several items adjusted to the Croatian context and to the specific aims of this paper. The survey focused on perceived familiarity with AI, AI use, domain-specific trust, perceived benefits and risks, emotional responses, reliance on AI and willingness to share information with AI. A total of 761 individuals accessed the survey. At the screening stage, 36 respondents were excluded because they reported no prior awareness of artificial intelligence, meaning that they had never heard, read or seen anything about the topic. In addition, 314 partial responses were excluded because they provided insufficient data for meaningful analysis, with most of them ending at the first question or within the first three questions. The final analytical sample consisted of 411 completed surveys. The sample was obtained through non-probability snowball sampling using digital distribution channels. Therefore, it should be interpreted as a sample of Croatian internet users rather than as a nationally representative sample of the Croatian population. The sample included 274 women, 136 men and one respondent who selected another gender category. The average age was 32.12 years ($SD = 11.68$), with respondents ranging from 18 to 82 years. In terms of education, 52.6% of respondents selected primary education, secondary education, or the combined questionnaire category “college / vocational or trade qualification”, 37.2% had a bachelor or graduate-level degree, and 10.2% had a postgraduate degree.

3.2. MEASURES

Overall AI trust was measured using eight items covering trust in four application domains: healthcare, security, recommender systems and human resources. The items concerned diagnosis and treatment, public-space surveillance and crime prevention, personalized product and social-media content recommendations, and candidate selection and employee performance assessment, respectively. Responses ranged from 1 = completely unwilling to 7 = completely willing to trust AI. Each domain was measured using two items, and domain-specific composite variables were calculated as the mean of the two items. Overall AI trust was calculated as the mean of all eight trust items. Thus, the overall score summarizes trust across these applications. Spearman–Brown reliability coefficients for the two-item measures were .883 for healthcare, .860 for security, .891 for recommender systems and .891 for human resources.

Perceived AI familiarity was measured with three items assessing whether respondents felt they knew what AI is, whether they felt informed about how AI is used, and whether they felt able to recognize when AI is being used. Responses ranged from 1 = not at all to 5 = to a very great extent. This composite captures subjective familiarity, not objectively demonstrated AI knowledge or literacy. Respondents were consequently grouped into low ($M < 2.50$; $n = 87$), moderate ($M = 2.50–3.50$; $n = 160$), and high ($M > 3.50$; $n = 164$) perceived AI familiarity groups for subgroup comparisons. These interpretative cut-offs place the moderate group around the response-scale midpoint of 3, with boundaries halfway towards the adjacent categories. They are neither sample terciles nor validated literacy thresholds. The continuous familiarity score was used in regression analyses.

Frequency of AI use was measured with one item asking respondents how often they use AI in work or study, coded from 0 = never to 5 = always or almost always. “Do not know” responses were treated as missing. Perceived benefits and perceived risks were each measured using nine items. Benefits concerned expected advantages, including improved efficiency, reduced costs and better decision-making; risks concerned worry about potential harms, including privacy loss, job displacement and bias. Both used scales from 1 = not at all to 5 = to a very great extent. Positive emotions were measured with three items: optimistic, excited and relaxed. Negative emotions were measured with three items: worried, afraid and angry. Emotion ratings ranged from 1 = not at all to 5 = extremely. Reliance on AI and willingness to share information with AI each used five items on 7-point willingness scales. Composite scores were item means; available-item means were used for reliance and information sharing when some items were missing. Cronbach’s alpha was calculated using complete item sets and ranged from .785 to .953 for the scales in Table 1.

3.3. DATA ANALYSIS

The original analysis was conducted in IBM SPSS Statistics 29. Descriptive statistics and reliability analyses were calculated first. Subgroup differences were examined using independent samples t-tests and one-way analysis of variance. For familiarity-group comparisons, conventional ANOVA with Tukey–Kramer post-hoc tests was used when the mean-centred Levene test was not significant at .05; otherwise, Welch’s ANOVA and Games–Howell tests were used. Eta squared (η^2) was calculated as the between-group sum of squares divided by the total sum of squares. Post-hoc comparisons followed significant omnibus tests, with adjustment for the three pairwise comparisons within each outcome. These comparisons were exploratory, without adjustment across outcomes. Pearson correlations were used to examine associations between age, perceived AI familiarity, AI use, trust, benefits, risks and emotional responses.

Hierarchical linear regression was used to examine predictors of overall AI trust. The first model included gender, age, education and work/study status. The second model added perceived AI familiarity and frequency of AI use. The third model added perceived benefits, perceived risks, positive emotions and negative emotions. Gender was coded 0 = male and 1 = female. Education was represented by two dummy variables for bachelor or graduate-level and postgraduate degrees, with the combined group of primary, secondary and college/vocational qualifications described in Section 3.1 as the reference. Work/study status was coded 0 = employed and 1 = student or studying while working.

All three regression models used the same 351 cases with complete data on the outcome and full predictor set. Of the 411 completed surveys, 39 respondents (32 unemployed and seven retired) were excluded because they were outside the binary work/study comparison. A further 20 respondents answered “do not know” to AI use, and one selected another gender category and was therefore not represented by the binary gender variable. Of the 26 “do not know” responses to AI use in the full sample, six overlapped with the work/study exclusions. These exclusions account for the entire reduction from 411 to 351; no further cases were removed. Multicollinearity was assessed using tolerance and variance inflation factor values. Regression coefficients were interpreted as conditional associations.

Grammarly was used for language correction, while ChatGPT 5.5 and Claude Opus 4.7 were used for textual refinement, editing support and figure editing. During revision, ChatGPT 6-Astra also assisted with preparing code for statistical verification and supplementary analyses.

The author remains fully responsible for the content, analysis, interpretation and final version of the paper.

4. RESULTS

4.1. DESCRIPTIVE RESULTS AND RELIABILITY

The descriptive results show cautious overall trust in AI, with the mean score slightly below the midpoint of the 7-point scale. The mean overall AI trust was 3.55 (SD = 1.26). Among the four observed application domains, trust was highest for recommender systems (M = 3.95, SD = 1.60) and security (M = 3.91, SD = 1.57), followed by healthcare (M = 3.21, SD = 1.55). Trust was lowest for AI in human resources (M = 3.14, SD = 1.50).

Perceived AI familiarity was moderate (M = 3.31, SD = 0.96). On average, AI use in work or study was close to occasional, measured on a scale from 0 = never to 5 = always or almost always (M = 1.93, SD = 1.42), with considerable variation in usage frequency. The mean score for concern about perceived risks (M = 3.63, SD = 0.83) was numerically higher than that for expected benefits (M = 3.22, SD = 0.98). Positive emotions toward AI were moderate (M = 2.72, SD = 0.99), while negative emotions were slightly lower (M = 2.61, SD = 0.95).

Table 1. Descriptive statistics and reliability of main constructs

CONSTRUCT	Items	M	SD	Cronbach's alpha
Perceived AI familiarity	3	3.31	0.96	.857
Overall AI trust	8	3.55	1.26	.898
Perceived benefits	9	3.22	0.98	.953
Perceived risks	9	3.63	0.83	.904
Positive emotions	3	2.72	0.99	.856
Negative emotions	3	2.61	0.95	.785
Reliance on AI	5	3.53	1.37	.923
Willingness to share information with AI	5	3.35	1.44	.946

Source: Author

Note: N = 411 for descriptive statistics, except information sharing (N = 410). Alpha uses complete item sets: N = 407 for reliance, N = 395 for information sharing and N = 411 for the remaining scales. Domain-specific trust was measured with two-item composites; Spearman–Brown coefficients are reported in Section 3.2.

4.2. DIFFERENCES BY PERCEIVED AI FAMILIARITY


Respondents were divided into three groups according to perceived AI familiarity: low familiarity (n = 87), moderate familiarity (n = 160) and high familiarity (n = 164). Figure 1 presents their mean overall and domain-specific AI trust.

For overall AI trust, the means were 3.02 in the low familiarity group, 3.49 in the moderate familiarity group and 3.90 in the high familiarity group, $F(2, 408) = 15.24$, $p < .001$, $\eta^2 = .070$. Significant differences were also observed for healthcare, Welch's $F(2, 240.92) = 12.93$, $p < .001$.

.001, $\eta^2 = .053$; security, $F(2, 408) = 12.39$, $p < .001$, $\eta^2 = .057$; and recommender systems, Welch's $F(2, 240.42) = 18.93$, $p < .001$, $\eta^2 = .079$. The largest observed domain effect size was for recommender systems, where the means ranged from 3.29 to 4.45. Tukey–Kramer comparisons for overall trust and security, and Games–Howell comparisons for healthcare and recommender systems, showed significant differences between all three group pairs, ordered low < moderate < high (all adjusted $p \leq .028$).

Trust in AI for human resources did not differ significantly across perceived familiarity groups, $F(2, 408) = 2.07$, $p = .128$, $\eta^2 = .010$. The means were 2.87 for the low familiarity group, 3.17 for the moderate familiarity group and 3.27 for the high familiarity group. This non-significant result does not establish equivalence between groups or demonstrate that the familiarity–trust association differs significantly between domains.

Figure 1. Overall and domain-specific AI trust by perceived AI familiarity



Source: Author

Note: Points represent group means on the 1–7 trust scale. Group comparisons are reported in the text.

The familiarity groups also differed in perceived benefits, positive emotions and AI use. Perceived benefits ranged from 2.50 in the low familiarity group to 3.64 in the high familiarity group, $F(2, 408) = 46.54$, $p < .001$, $\eta^2 = .186$. Positive emotions ranged from 2.03 to 3.11, Welch's $F(2, 239.02) = 45.02$, $p < .001$, $\eta^2 = .165$. AI use ranged from 0.97 to 2.59, Welch's $F(2, 208.42) = 47.03$, $p < .001$, $\eta^2 = .187$. Tukey–Kramer comparisons for benefits and Games–Howell comparisons for positive emotions and AI use showed low < moderate < high for every pair (all adjusted $p < .001$). Negative emotions did not differ significantly, Welch's $F(2, 216.41) = 0.23$, $p = .795$, $\eta^2 = .001$.

Reliance on AI, $F(2, 408) = 20.58$, $p < .001$, $\eta^2 = .092$, and willingness to share information, $F(2, 407) = 18.11$, $p < .001$, $\eta^2 = .082$, also differed between familiarity groups. Tukey–Kramer comparisons showed low < moderate < high for all three pairs in each outcome (all adjusted $p \leq .035$).

4.3. HIERARCHICAL REGRESSION PREDICTING OVERALL AI TRUST

Hierarchical regression models for overall AI trust were estimated on the same 351 respondents (Table 2; see Section 3.3 for sample exclusions and variable coding).

The first model was statistically significant and explained 8.6% of the variance in overall AI trust, $R^2 = .086$, $F(5, 345) = 6.50$, $p < .001$. In this model, education and student status were significant predictors. The second model explained 24.3% of the variance, $R^2 = .243$, $F(7, 343) = 15.72$, $p < .001$. Adding perceived AI familiarity and AI use significantly improved the model, $\Delta R^2 = .157$, $p < .001$. In this model, frequency of AI use was the strongest predictor, followed by perceived AI familiarity. Work/study status was no longer significant after these two variables were included. The final model explained 47.6% of the variance in overall AI trust, $R^2 = .476$, $F(11, 339) = 27.95$, $p < .001$. Adding perceived benefits, perceived risks and emotions significantly improved the model, $\Delta R^2 = .233$, $p < .001$. In the final model, perceived benefits were the strongest predictor of overall AI trust, followed by positive emotions. Age and postgraduate education also remained significant, but with smaller standardized coefficients. Perceived AI familiarity and AI use were no longer significant after benefits and emotions were added. Perceived risks and negative emotions were also not significant predictors. Multicollinearity diagnostics did not indicate problematic levels of multicollinearity, with all VIF values below 3 (maximum = 2.79).

Table 2. Hierarchical regression predicting overall AI trust

Predictor	Model 1 β (p)	Model 2 β (p)	Model 3 β (p)
Female	-.096 (.073)	-.094 (.058)	-.050 (.239)
Age	.080 (.217)	.141 (.018)	.125 (.014)
Bachelor or graduate-level degree	.180 (.003)	.113 (.045)	.071 (.136)
Postgraduate degree	.211 (< .001)	.111 (.033)	.127 (.004)
Student / studying while working	.165 (.018)	-.019 (.775)	-.018 (.751)
Perceived AI familiarity		.172 (.002)	.020 (.690)
Frequency of AI use		.368 (< .001)	.068 (.222)
Perceived benefits			.447 (< .001)
Perceived risks			.015 (.747)
Positive emotions			.206 (.002)
Negative emotions			-.071 (.125)
R^2	.086	.243	.476
Adjusted R^2	.073	.227	.459
ΔR^2	.086 (< .001)	.157 (< .001)	.233 (< .001)

Source: Author

Note: Coefficient rows show standardized β with two-sided p-values in parentheses; parentheses in the ΔR^2 row report p-values for block changes. N = 351 in all models. Reference categories: male, primary/secondary/college or vocational qualifications (see Section 3.1), and employed respondents. Blank cells indicate predictors not included in a model.

5. DISCUSSION

The study contributes exploratory evidence on how perceived familiarity and AI use in work or study relate to trust when evaluations and emotions are considered jointly. It treats familiarity as a subjective assessment and examines trust across four application domains. The findings support considering user experience, expected value and affect together, consistent with a multifaceted view of user trust (Yang & Wibowo, 2022). The relatively limited explanatory contribution of demographics applies to these measures and this sample; it should not be generalized to all users or AI contexts.

The familiarity measure concerns how informed respondents feel. Higher scores therefore cannot establish greater technical understanding or more accurate judgements about AI. The smaller familiarity and use coefficients in the full model indicate shared explanatory variance with benefits and emotions. Several interpretations remain possible: experience may inform favourable evaluations, greater trust may encourage use, or a generally favourable orientation towards AI may underlie these responses. The cross-sectional design cannot distinguish these accounts, and the regression sequence does not test mediation.

Perceived benefits and positive emotions retained conditional associations with trust, but these should not be treated as independent causal mechanisms. Expected improvements in efficiency or decision-making concern anticipated value, while optimism and excitement concern affective responses. This interpretation is compatible with Kreps et al. (2023), who link support for AI use to benefit–risk assessments, efficiency beliefs and optimism even where trust is limited. The non-significant coefficients for risk concern and negative emotions concern their additional associations in the full model; they do not establish that concern is absent or unimportant.

The change in the student-status coefficient suggests that the initial contrast overlaps with familiarity and usage patterns. It does not establish why students and employed respondents differ. Postgraduate education and age retained associations in the full model, which also cautions against dismissing demographic differences. These coefficients describe respondents within the restricted employed/student regression sample.

The small observed differences in HR trust raise the possibility that general feelings of familiarity are less informative for judgements about candidate selection and employee evaluation. Concerns about fairness, personal consequences or opportunities to challenge decisions offer possible explanations, but these mechanisms were not tested. Araujo et al. (2020) similarly distinguish general perceptions of automated decision-making from evaluations of specific decisions. Here, non-significance in HR does not establish equivalence between groups, and separate domain tests do not demonstrate a difference between the domain-specific associations.

For organizations, the findings motivate testing communication that explains application-specific benefits alongside limitations, safeguards and human oversight. Familiarity scores or usage frequency alone should not be treated as evidence of informed trust. The present study does not establish that making users feel more familiar, optimistic or positive about benefits would increase justified trust. Intervention studies would be needed to assess such communication strategies.

Several limitations should be acknowledged. The study uses a non-probability sample of Croatian internet users, with relatively young respondents and more women than men. It is not representative of the Croatian population. Screening excluded individuals without prior AI awareness, and only completed surveys were retained, creating possible selection and dropout bias. The regression sample is further restricted to 351 respondents represented by the work/study and gender coding and with usable AI-use responses. The regression findings therefore apply to a more restricted subset of the analytical sample.

The cross-sectional, self-report design prevents causal inference. Since all constructs were measured using the same survey at a single point in time, common-method variance may have inflated some of the observed associations between trust, perceived benefits, risks and emotions. Perceived benefits, positive emotions and willingness to trust AI may also share a broader favourable evaluation of AI. Their different item content does not rule out conceptual overlap, and internal consistency and acceptable VIF values do not establish discriminant validity. The relative sizes of their coefficients should therefore be interpreted cautiously.

Subjective familiarity does not measure objective AI literacy. AI use was measured through self-reported frequency of use in work or study, without observing actual behavior, specific AI tools used, broader personal use, or passive exposure to AI-enabled services such as recommender systems, search engines, navigation or social media. Respondents may also have interpreted the broad concept of AI differently. The overall trust score averages eight application-specific items rather than a separate general-trust item. Although the questionnaire was based on an established global research framework, its partial adaptation limits direct comparability with global benchmark studies.

Future research could combine representative samples and longitudinal designs with objective or scenario-based measures of AI literacy, observed use and domain-specific decision scenarios. Measurement models could examine construct distinctiveness, while appropriately designed longitudinal studies could test possible indirect relationships between familiarity, benefits, emotions and trust.

6. CONCLUSION

This study provides exploratory evidence from Croatian internet users that perceived familiarity and AI use add explanatory value beyond demographic and status characteristics, while perceived benefits and positive emotions have the largest standardized coefficients in the full model. These findings concern self-perceptions and associations, not demonstrated AI knowledge or causal pathways. The absence of a significant familiarity-group difference in HR trust also cautions against assuming that general familiarity is equally informative across applications. The contribution lies in examining experience, evaluation and emotion jointly while retaining attention to application context. For organizations, the findings identify issues to assess when communicating about AI; they do not establish the effectiveness of particular trust-building interventions.

ACKNOWLEDGEMENT

This research is the result of the project DIMPACT (Transformation of Marketing Practices in the Era of Disruptions: Integrative Effects of Digital Innovations, Changes in Consumer

Behaviour and Contemporary Market Challenges, 581-UNIOS-11), funded by the European Union – NextGenerationEU. The views and opinions expressed are solely those of the author(s) and do not necessarily reflect those of the European Union or the European Commission. Neither the European Union nor the European Commission can be held responsible for them. During the preparation of this work, the authors used Grammarly to refine the English language, improve text flow, and perform minor language corrections such as summarization. Additionally, ChatGPT 5.5, Claude Opus 5.5 and Gemini 3.1 Pro were utilized for accuracy checks, text corrections, creating data visualizations (graphs), and assisting with the synthesis of extracted studies. After using these tools/services, the authors reviewed and edited the content as needed and take full responsibility for the final content of the publication.

REFERENCES

1. Araujo, T., Helberger, N., Kruikemeier, S., & de Vreese, C. H. (2020). In AI we trust? Perceptions about automated decision-making by artificial intelligence. *AI & Society*, 35(3), 611–623. <https://doi.org/10.1007/s00146-019-00931-w>
2. Biloš, A., & Budimir, B. (2023). How much do we trust in AI? Exploring the impact of artificial intelligence on user trust levels. In D. Bećirović & D. Arnaut (Eds.), 6. *međunarodna naučna konferencija o digitalnoj ekonomiji DIEC 2023* (pp. 23–41). Visoka škola za savremeno poslovanje, informacione tehnologije i tržišne komunikacije “Internacionalna poslovno-informaciona akademija” Tuzla.
3. Cugurullo, F., & Acheampong, R. A. (2024). Fear of AI: An inquiry into the adoption of autonomous cars in spite of fear, and a theoretical framework for the study of artificial intelligence technology acceptance. *AI & Society*, 39(4), 1569–1584. <https://doi.org/10.1007/s00146-022-01598-6>
4. Ding, W., Wu, Y., & Wang, J. (2026). Beyond risk reduction: Vigilant trust in artificial intelligence based on evidence from China. *Behavioral Sciences*, 16(1), Article 95. <https://doi.org/10.3390/bs16010095>
5. Gillespie, N., Lockey, S., Curtis, C., Pool, J., & Akbari, A. (2023). *Trust in artificial intelligence: A global study*. The University of Queensland and KPMG Australia. <https://doi.org/10.14264/00d3c94>
6. Gillespie, N., Lockey, S., Ward, T., Macdade, A., & Hased, G. (2025). *Trust, attitudes and use of artificial intelligence: A global study 2025*. The University of Melbourne and KPMG. <https://doi.org/10.26188/28822919>
7. Glikson, E., & Woolley, A. W. (2020). Human trust in artificial intelligence: Review of empirical research. *Academy of Management Annals*, 14(2), 627–660. <https://doi.org/10.5465/annals.2018.0057>
8. Horowitz, M. C., Kahn, L., Macdonald, J., & Schneider, J. (2024). Adopting AI: How familiarity breeds both trust and contempt. *AI & Society*, 39(4), 1721–1735. <https://doi.org/10.1007/s00146-023-01666-5>
9. Huang, K.-T., & Ball, C. (2024). The influence of AI literacy on user’s trust in AI in practical scenarios: A digital divide pilot study. *Proceedings of the Association for Information Science and Technology*, 61(1), 937–939. <https://doi.org/10.1002/pra2.1146>
10. Jacovi, A., Marasović, A., Miller, T., & Goldberg, Y. (2021). Formalizing trust in artificial intelligence: Prerequisites, causes and goals of human trust in AI. In *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency* (pp. 624–635). Association for Computing Machinery. <https://doi.org/10.1145/3442188.3445923>

11. Kaplan, A. D., Kessler, T. T., Brill, J. C., & Hancock, P. A. (2023). Trust in artificial intelligence: Meta-analytic findings. *Human Factors*, 65(2), 337–359.
<https://doi.org/10.1177/00187208211013988>
12. Kerstan, S., Bienefeld, N., & Grote, G. (2024). Choosing human over AI doctors? How comparative trust associations and knowledge relate to risk and benefit perceptions of AI in healthcare. *Risk Analysis*, 44(4), 939–957. <https://doi.org/10.1111/risa.14216>
13. Kreps, S., George, J., Lushenko, P., & Rao, A. (2023). Exploring the artificial intelligence “trust paradox”: Evidence from a survey experiment in the United States. *PLOS ONE*, 18(7), Article e0288109. <https://doi.org/10.1371/journal.pone.0288109>
14. Lockey, S., Gillespie, N., Holm, D., & Someh, I. A. (2021). A review of trust in artificial intelligence: Challenges, vulnerabilities and future directions. In *Proceedings of the 54th Hawaii International Conference on System Sciences* (pp. 5463–5472). Hawaii International Conference on System Sciences. <https://doi.org/10.24251/HICSS.2021.664>
15. Montag, C., Kraus, J., Baumann, M., & Rozgonjuk, D. (2023). The propensity to trust in (automated) technology mediates the links between technology self-efficacy and fear and acceptance of artificial intelligence. *Computers in Human Behavior Reports*, 11, Article 100315. <https://doi.org/10.1016/j.chbr.2023.100315>
16. Ryan, M. (2020). In AI we trust: Ethics, artificial intelligence, and reliability. *Science and Engineering Ethics*, 26(5), 2749–2767. <https://doi.org/10.1007/s11948-020-00228-y>
17. Schmidt, P., Biessmann, F., & Teubner, T. (2020). Transparency and trust in artificial intelligence systems. *Journal of Decision Systems*, 29(4), 260–278.
<https://doi.org/10.1080/12460125.2020.1819094>
18. Shi, S., Gong, Y., & Gursoy, D. (2021). Antecedents of trust and adoption intention toward artificially intelligent recommendation systems in travel planning: A heuristic-systematic model. *Journal of Travel Research*, 60(8), 1714–1734.
<https://doi.org/10.1177/0047287520966395>
19. Wang, B., Rau, P.-L. P., & Yuan, T. (2023). Measuring user competence in using artificial intelligence: Validity and reliability of artificial intelligence literacy scale. *Behaviour & Information Technology*, 42(9), 1324–1337.
<https://doi.org/10.1080/0144929X.2022.2072768>
20. Yang, R., & Wibowo, S. (2022). User trust in artificial intelligence: A comprehensive conceptual framework. *Electronic Markets*, 32(4), 2053–2077.
<https://doi.org/10.1007/s12525-022-00592-6>

CAN GENAI SUPPORT BUSINESS MODEL INNOVATION IN THE CONTEXT OF DIGITAL TRANSFORMATION? A MULTIPLE-CASE STUDY OF TWO SMES

MATIJA ŠAJN

University of Zagreb

Faculty of Organization and Informatics

Pavlinka 2, 42000 Varaždin, Croatia

matija.sajn@foi.unizg.hr

ABSTRACT

Business model innovation is increasingly important for small and medium-sized enterprises (SMEs) navigating digital transformation, while generative artificial intelligence (GenAI) offers new possibilities for strategic analysis. Empirical evidence on the integration of large language models (LLMs) into structured business model innovation processes, however, remains limited. This study examines an AI-assisted business model innovation procedure through a multiple case study of two Croatian SMEs in different segments of food and beverage production. The procedure combines semi-structured interviews, Business Model Canvas (BMC) reconstruction and validation, LLM-based recommendation generation, managerial evaluation, and cross-case analysis. Based on validated BMCs, the LLM generated 18 recommendations across business model innovation, digital transformation, and AI adoption. The decision-maker in Case A evaluated AI adoption most favourably, whereas the decision-maker in Case B evaluated business model innovation and digital transformation most favourably. Of the 18 recommendations, 10 were considered suitable as generated, seven with modifications, and one was rejected. Recurring recommendations concerned digitalised information and traceability, planning, and customer communication, although their specific form reflected each SME's business model. The study contributes a structured procedure in which a validated BMC provides the basis for LLM-generated strategic alternatives subject to contextual managerial evaluation.

KEYWORDS: Business Model Canvas, business model innovation, generative artificial intelligence, large language models, digital transformation, SMEs, multiple case study

1. INTRODUCTION

Digital transformation is reshaping how firms create, deliver, and capture value, requiring organisations to reconsider established processes, capabilities, and business models (Verhoef et al., 2021). For small and medium-sized enterprises (SMEs), this transition is particularly challenging because limited financial resources, digital capabilities, and technological readiness can constrain transformation efforts (Jafari-Sadeghi et al., 2023). Recent SME research has identified similar barriers related to skills and organisational preparedness (Elsa et al., 2025), while OECD (2024) evidence indicates that the adoption of advanced digital technologies

remains uneven across SMEs. Business models describe the architecture through which firms create, deliver, and capture value (Teece, 2010). Business model innovation may involve changes ranging from individual components and extensions of an existing model to more substantial reconfigurations (Foss & Saebi, 2017). In SMEs, such changes are often incremental rather than radical (Clauss et al., 2022). The Business Model Canvas (BMC) offers a structured representation of these elements through nine interrelated building blocks (Osterwalder, 2004; Osterwalder & Pigneur, 2010). The BMC has also been applied to digital transformation and organisational readiness in SMEs (Kutnjak, 2026), as well as to broader sustainability-related considerations (Bachmann et al., 2025).

Generative artificial intelligence (GenAI) introduces new possibilities for business model analysis and innovation by supporting information synthesis, knowledge generation, and strategic decision-making (Rajaram & Tinguely, 2024). For SMEs, adoption remains constrained by limited resources, skills, and organisational readiness (OECD, 2025). Kanbach et al. (2024) show that GenAI can influence multiple business model components, while Teng et al. (2025) distinguish between its role in incremental and more radical forms of business model innovation. Recent empirical studies associate GenAI adoption with business model innovation and organisational transformation (Taksi Deveciyan et al., 2026; Wishah et al., 2026).

The systematic integration of GenAI into structured business model innovation procedures remains underexplored. Recent research on AI and strategic decision-making indicates that LLMs can contribute to both strategy generation and evaluation, potentially augmenting existing strategic decision-making tools (Csaszar et al., 2024). Brunner et al. (2026) highlight its role in business model initiation and ideation, while Doshi et al. (2025) show that individual LLM evaluations can be inconsistent and biased, reinforcing the need for human judgement. What remains insufficiently examined is how a validated representation of an SME's existing business model can serve as structured input for LLM-generated recommendations that are subsequently evaluated by decision-makers across different organisational contexts.

This study investigates an AI-assisted business model innovation procedure in two Croatian SMEs operating in different segments of food and beverage production. Validated BMCs are used as structured inputs for generating recommendations in business model innovation, digital transformation, and AI adoption. SME decision-makers subsequently evaluate these recommendations according to strategic fit, feasibility, expected business value, and implementation effort, after which the results are compared across the two organisational contexts.

The study is guided by the following research questions:

RQ1: What business model innovation, digital transformation, and AI adoption recommendations can the selected LLM generate based on validated Business Model Canvas representations of SMEs?

RQ2: How do SME decision-makers evaluate AI-generated recommendations regarding strategic fit, feasibility, expected business value, and implementation effort?

RQ3: What common and context-specific patterns emerge across two SMEs following the application of the proposed AI-assisted business model innovation procedure?

2. RESEARCH METHODOLOGY


This study employed a qualitative multiple case study design to examine an AI-assisted business model innovation procedure in two Croatian SMEs. It combined qualitative data collection, structured business model representation, AI-assisted analysis, and managerial evaluation.

2.1. RESEARCH DESIGN AND DATA COLLECTION

A multiple case study design was selected to support analytical comparison across organisational settings while preserving their contextual characteristics (Yin, 2018). Two Croatian SMEs operating in different segments of food and beverage production were purposively selected. The cases provided contrasting business models within the same broader sector. Given the small and purposively selected sample, the study aims at analytical comparison between the cases rather than statistical generalisation to the broader SME population.

The procedure comprised four sequential stages: (1) business model reconstruction, (2) BMC validation, (3) LLM-based recommendation generation, and (4) managerial evaluation followed by cross-case comparison. The overall research workflow is presented in Fig. 1.

Figure 1. Research workflow of the proposed AI-assisted business model innovation procedure



Source: Author

The validated BMCs provided the input for AI-assisted recommendation generation. In this way, the analysis was based on an owner-validated representation of the existing business model.

Data were collected through one semi-structured interview with the owner of each SME. The interviews for both cases were conducted in August 2026, and the reconstructed BMCs were validated by the respective decision-makers in September 2026. Both interviews lasted approximately 45–60 minutes and followed the same protocol structured around the nine BMC

building blocks: value propositions, customer segments, channels, customer relationships, key activities, key resources, key partners, revenue streams, and cost structures (Osterwalder & Pigneur, 2010).

Based on the interview data, a current-state BMC was reconstructed for each company and then reviewed with the respective owner. Necessary corrections were incorporated before the canvases were approved as final representations of the existing business models and used as inputs for LLM-based recommendation generation.

2.2. AI-ASSISTED RECOMMENDATION GENERATION AND EVALUATION

The validated BMCs were provided as image-based inputs to the multimodal large language model Claude Sonnet 5 (Anthropic) through the Claude desktop application on 9 September 2026, using an identical prompt for both cases. Extended reasoning and memory features were not enabled, and temperature was not user-configurable through the interface. Both cases were analysed sequentially within the same new conversation, with a single response generated and retained for each case without iterative prompting, refinement, or substantive editing. The conversational context from Case A was therefore technically available to the model when Case B was analysed, although the Case B prompt did not refer to or explicitly draw on the preceding case. Web search and external knowledge retrieval were disabled, restricting the model to the information provided within the conversation. Data use for model training was disabled. The complete prompt is provided in Appendix A.

The model generated recommendations in three predefined areas: business model innovation, digital transformation, and AI adoption. Business model innovation was included because SMEs often adapt through incremental changes to existing business models (Clauss et al., 2022). Digital transformation reflects the broader integration of digital technologies into value creation and organisational processes. AI adoption was treated separately, reflecting both the growing use of GenAI for strategic analysis and decision support (Rajaram & Tinguely, 2024) and the opportunities and adoption challenges identified for SMEs (OECD, 2025). Three recommendations were generated in each area, resulting in nine recommendations per case. Each recommendation included a title, a concise description grounded in the current business model, and the expected benefit. The model was instructed not to evaluate or rank the recommendations. Strategic fit, feasibility, expected business value, and implementation effort were left for the SME decision-makers to assess.

The generated recommendations were evaluated by the participating SME decision-makers according to four author-defined criteria: strategic fit, feasibility, expected business value, and implementation effort, each using a five-point scale (1 = very low, 5 = very high). Participants also indicated whether they would consider implementing each recommendation by selecting one of three response options: 'Yes', 'Yes, with modifications', or 'No'. An optional open-text field allowed participants to explain their evaluation or specify required modifications. Neither decision-maker provided qualitative comments. The evaluation was administered through Google Forms one week after BMC validation, with each recommendation presented in full. The same decision-maker who participated in the interview and BMC validation completed the evaluation independently, without the researcher being present, and was informed that the recommendations had been generated using Claude Sonnet 5.

The two cases were then compared to identify recurring and case-specific recommendation patterns and differences in managerial evaluations. The comparison was analytical rather than statistical and preserved the contextual characteristics of each case (Yin, 2018).

3. RESULTS

The results first present the reconstructed current business models, followed by the AI-generated recommendations and their managerial evaluation. The final part compares recurring and context-specific patterns across the two SMEs.

3.1. CURRENT BUSINESS MODEL RECONSTRUCTION

The two cases represent Croatian B2B SMEs operating in different segments of food and beverage production. Their main characteristics are summarised in Table 1. The interview findings resulted in two current-state BMCs, which were then reviewed and validated by the respective company owners. The validated canvases are presented in Fig. 2 and Fig. 3.

Table 1. Anonymised profiles of the participating SMEs

Attribute	Case A	Case B
Company type	Small manufacturing SME	Small specialised service/manufacturing SME
Industry	Food manufacturing (meat processing)	Sparkling wine production services
Company age	More than 10 years	Established in 2026
Company size	Approximately 15–20 employees	Approximately 5–10 employees
Primary market	National market	Croatia, with initial expansion to Slovenia and Austria
Digitalisation	Accounting/inventory software; Excel-based production planning; no integrated ERP, CRM or BI	Integrated accounting, commercial and inventory software; Excel-based production planning; production tracking not fully integrated
AI adoption	Informal GenAI use; no formal AI strategy or governance	GenAI used for communication, marketing, research and business support; no AI-based production decisions

Source: Author

The two cases differ considerably in their current business model configurations. Case A represents an established manufacturing-oriented business model centred on traditional food products, production capabilities, operational reliability, and long-term relationships with retail partners. Case B represents a service-oriented business model in which value is created by providing wineries with access to specialised expertise, equipment, and integrated sparkling-wine production services without requiring substantial internal investment. At the time of data collection, Case B was operational, and all elements represented in its BMC had already been implemented rather than reflecting intended or planned activities. Despite these differences, both cases rely strongly on specialised knowledge, operational reliability, and long-term customer relationships.

Figure 2. BMC reconstructed from the interview findings – Case A (current state)

Key Partnerships	Key Activities	Value Propositions	Customer Relationships	Customer Segments
- Raw material suppliers - Packaging suppliers - Retail partners - Equipment and maintenance providers	- Procurement of raw materials - Production planning - Meat processing - Quality assurance and traceability - Distribution - Customer communication	- Traditional pork products - Consistent product quality - Food safety and product traceability - Reliable product availability - Long-term reliability as a business partner	- Long-term business relationships - Direct communication with customers - Prompt response to customer requests - Trust based on consistent cooperation	- Major national retail chains - Business customers (B2B) - End consumers through retail partners - Croatian market
	Key Resources - Production facilities - Meat-processing equipment - Cold-storage facilities - Company-owned transportation - Employees' knowledge and experience - Food safety management system		Channels - Direct sales to retail chains - Distribution through retail partners - Company-owned transportation - Electronic communication with customers - Planned company website	
Cost Structure - Raw materials - Logistics - Labor - Food safety and certification costs - Energy - Packaging		Revenue Streams - Sales of traditional pork products - Private-label production - Sales of complementary pork products - Sales of rendered pork fat		

Source: Author

Figure 3. BMC reconstructed from the interview findings – Case B (current state)

Key Partnerships	Key Activities	Value Propositions	Customer Relationships	Customer Segments
- Wineries and wine producers - Suppliers of bottles, closures and packaging materials - Suppliers of oenological products and additives - Equipment suppliers and service providers - Oenologists and laboratories - Logistics and transport providers - Label and packaging design partners	- Production planning and scheduling - Consulting and analysis of base wine - Sparkling wine production (secondary fermentation) - Remuage and disgorgement - Final bottle finishing and packaging - Quality control and batch traceability - Procurement and inventory management - Customer consulting and support	- End-to-end support for traditional-method sparkling wine production - Access to specialized expertise and equipment without major customer investment - Integrated services and materials from a single partner - Flexible solutions for small production batches - High product quality and consistency - Reduced technological, financial and organizational risk - Personalized professional support	- Direct and personal communication - Advisory and consultative relationship - Long-term cooperation across production cycles - Ongoing communication about production status - Individualized support and tailored solutions - Trust based on reliability and expertise	- Croatian wineries producing or planning traditional-method sparkling wines - Small and medium-sized wineries without specialized equipment or expertise - Wineries requiring individual production stages (e.g., remuage, disgorgement) - Wineries seeking complete production support from base wine to finished product
	Key Resources - Oenological knowledge and expertise - Specialized production equipment - Production and storage facilities - Skilled personnel and collaborators - Supplier network and relationships - Customer base and reputation - Standardized procedures and project data		Channels - Direct sales and personal contacts - Referrals and professional networks - Telephone and e-mail - Company website - Social media - Direct pickup and delivery to customers	
Cost Structure - Raw materials and supplies - Equipment investment and depreciation - Equipment maintenance - Labor - Energy - Production and storage facilities - Transportation and logistics - Inventory holding and operating costs - Setup costs associated with small production batches		Revenue Streams - Fees for individual production services - Per-bottle service charges - Complete service packages - Storage and logistics services - Margins from sales of materials and equipment - Consulting and new product development - Complete project management from base wine to finished product		

Source: Author

3.2. AI-GENERATED RECOMMENDATIONS

The LLM generated nine recommendations for each case, distributed equally across business model innovation, digital transformation, and AI adoption. The resulting 18 recommendations are presented in Table 2.

Table 2. AI-generated recommendations across the two case studies

Area	Case A	Case B
Business Model Innovation (BMI)	A-BMI1 [E/R]: Launch direct-to-consumer channel; A-BMI2 [E/R]: Expand private-label and complementary product lines; A-BMI3 [E/R]: Introduce traceability as a value proposition for premium segments	B-BMI1 [E/R]: Introduce tiered subscription/retainer service packages; B-BMI2 [E/R]: Formalise a materials and equipment resale/consulting offering; B-BMI3 [E/R]: Develop capacity-sharing offering for small-batch clients
Digital Transformation (DT)	A-DT1 [O]: Launch and operationalise the planned company website; A-DT2 [E/R]: Digitise traceability and quality assurance data; A-DT3 [E/R]: Implement a digital platform for retail partner communication and orders	B-DT1 [E/R]: Implement a digital batch traceability and production-status system; B-DT2 [E/R]: Expand company website into a client portal; B-DT3 [E/R]: Digitise inventory and procurement management
AI Adoption (AI)	A-AI1 [E/R]: AI-assisted demand and production planning; A-AI2 [E/R]: AI-supported quality and traceability monitoring; A-AI3 [E/R]: AI-powered customer communication support	B-AI1 [E/R]: AI-assisted production scheduling for small-batch planning; B-AI2 [E/R]: AI-supported base wine analysis; B-AI3 [E/R]: AI-based customer inquiry and status assistant

Source: Author

Note. O = operationalisation of an existing BMC element; E/R = extension or reconfiguration of one or more existing BMC elements. The classification indicates each recommendation's relationship to the validated input BMC; it does not represent a quantitative measure of novelty.

The comparison with the validated BMCs showed that 17 of the 18 recommendations extended or reconfigured existing business model elements, while A-DT1 operationalised an element already explicitly planned in the BMC. The recommendations typically combined existing activities, resources, channels, or value propositions with new digital, AI-enabled, or organisational mechanisms rather than introducing unrelated strategic options. This was consistent with the generation procedure, which required recommendations to build on the validated current-state BMCs.

3.3. MANAGERIAL EVALUATION

Table 3 summarises the managerial evaluations across the two cases and three recommendation areas. Mean scores are reported for strategic fit, feasibility, expected business value, and implementation effort. The first three criteria indicate how positively a recommendation was perceived, whereas a higher implementation effort reflects greater organisational, financial, technological, or human requirements and is therefore interpreted separately. Individual scores for all 18 recommendations, together with the corresponding implementation-consideration decisions, are reported in Appendix B.

Table 3. Mean managerial evaluation scores by case and recommendation area

Case	Recommendation area	Strategic fit	Feasibility	Expected business value	Implementation effort
Case A	Business Model Innovation	3.0	2.7	3.0	3.7
	Digital Transformation	3.3	3.7	3.0	3.0
	AI Adoption	4.3	4.3	4.3	2.3
Case B	Business Model Innovation	4.7	4.7	4.3	3.3
	Digital Transformation	4.7	4.0	4.7	3.3
	AI Adoption	4.0	3.3	4.0	3.7

Source: Author

In Case A, AI adoption received the most favourable evaluations across strategic fit, feasibility, and expected business value, while also receiving the lowest implementation-effort score. Business model innovation received more cautious assessments, particularly for the direct-to-consumer recommendation (A-BMI1), which was the only recommendation rejected by the decision-maker. In Case B, business model innovation and digital transformation received the strongest evaluations. None of the recommendations were rejected; four were considered suitable as generated and five were considered suitable with modifications. AI adoption was also evaluated positively, although its feasibility was assessed more cautiously than that of the other two recommendation areas.

Across both cases, 10 of the 18 recommendations were considered suitable as generated, seven were considered suitable with modifications, and one was rejected. In total, 17 recommendations (94.4%) therefore remained under consideration by the SME decision-makers, although seven required modification.

3.4. CROSS-CASE FINDINGS

Across the two cases, recurring recommendations concerned digitalised traceability and operational information, AI-supported planning, and digital or AI-based customer communication. Their specific form reflected the underlying business models: Case A recommendations centred on an established manufacturing setting and relationships with retail partners, whereas those for Case B reflected specialised production services, small-batch planning, and a combination of service- and material-based revenues.

4. DISCUSSION

The differences in managerial evaluations between the two cases should be interpreted in relation to their different organisational contexts. Case A has operated for more than a decade and has established production routines and retail relationships, whereas Case B was established in 2026 and operates through a specialised service/manufacturing model. With only two cases, the observed differences cannot be attributed to firm maturity and are treated here as context-specific patterns. In Case A, the AI-related proposals largely augmented existing activities such as production planning, quality monitoring, and customer communication. The direct-to-consumer recommendation (A-BMI1) was the only recommendation rejected by a decision-maker. Although it would have required changes to Case A's established channels and customer relationships, no qualitative comment was provided explaining the rejection; its underlying rationale therefore cannot be established from the collected data. Case B showed stronger evaluations of business model innovation and digital transformation recommendations, but the collected data do not establish why these categories were assessed more favourably. Resource, capability, and digital-readiness constraints identified in SME research (Jafari-Sadeghi et al., 2023; OECD, 2024) remain relevant when considering AI adoption separately from broader business model change.

The recommendations also differed in the extent of change they implied. Seventeen of the 18 recommendations extended or reconfigured existing business model elements, while one operationalised an already planned element. This is consistent with business model innovation encompassing changes to individual components and extensions of existing business models rather than only comprehensive reconfiguration (Foss & Saebi, 2017), and with the dynamic perspective of business model development as a process involving experimentation, adaptation, and trial-and-error learning (Sosna et al., 2010). It also corresponds to the distinction made by Wishah et al. (2026) between first-order operational improvements and second-order business model effects. The high proportion of recommendations remaining under consideration (17 of 18) may therefore partly reflect their proximity to activities, capabilities, and priorities already recognised by the decision-makers. The value of the procedure should consequently not be interpreted primarily as generating wholly novel business models, but as identifying contextually grounded extensions and alternative uses of existing business model elements.

Seven of the 18 recommendations were considered suitable with modifications, while one was rejected. As no optional qualitative comments were provided, the specific modifications required by the decision-makers and the reason for the rejection cannot be determined from the collected data. The evaluation nevertheless distinguishes between recommendations considered suitable as generated, those requiring further managerial adaptation, and those considered unsuitable. This distinction reinforces the need for human judgement when evaluating AI-generated alternatives (Doshi et al., 2025). This supports the role of GenAI as an ideation and analytical aid rather than an autonomous decision-maker (Brunner et al., 2026). It is also consistent with an augmentation perspective in which AI supports managerial tasks while human expertise remains involved in evaluating and complementing machine-generated outputs (Raisch & Krakowski, 2021). In the present cases, the LLM generated strategic options, but the decision-makers determined whether those options were suitable in their organisational context.

The validated BMC also played a specific role by linking qualitative organisational knowledge with LLM-based recommendation generation. A related use of the BMC in connecting organisational context with transformation recommendations can be found in Kutnjak (2026),

whose modified BMC incorporates a digital transformation readiness self-assessment from which personalised recommendations for SMEs are developed. In the present study, the mechanism differs: rather than deriving recommendations from a predefined readiness instrument, the validated current-state BMC was provided directly to the LLM as structured organisational input. This provided a common basis for applying the same model and prompting procedure across two different business models while retaining their contextual differences. Although the study does not establish whether the BMC is preferable to other forms of organisational representation, its use enabled recommendations to be grounded in each SME's existing business model and subsequently subjected to managerial evaluation.

5. CONCLUSION

This study examined an AI-assisted business model innovation procedure in two Croatian SMEs operating in different segments of food and beverage production. Starting from validated Business Model Canvas representations, the LLM generated recommendations across business model innovation, digital transformation, and AI adoption. Some patterns recurred across the cases, particularly recommendations concerning digitalised information and traceability, planning, and customer communication, while others reflected the specific business model of each SME. Most recommendations remained under consideration by the decision-makers, although several required modification and one was rejected. The evaluations also show that generated alternatives need to be considered within the organisational context in which they are assessed.

The main contribution lies in the procedure through which these alternatives were generated and evaluated rather than in the individual recommendations themselves. Theoretically, the study links business model representation with AI-assisted strategic ideation by showing how a validated current-state BMC can structure the organisational context provided to an LLM while managerial judgement remains a separate evaluation stage. In practice, SMEs, consultants, and business support institutions could apply the procedure as a structured starting point for identifying contextually grounded business model, digital transformation, and AI adoption alternatives. Three safeguards from the study design should be retained when applying the procedure: validation of the organisational input, transparent prompting, and human evaluation of generated recommendations before any implementation decision.

The findings remain bounded by the study design. The two SMEs were purposively selected, and the same decision-maker in each company participated in both BMC validation and the subsequent evaluation of AI-generated recommendations. The resulting assessments therefore represent individual managerial perspectives rather than organisational consensus, while the dependency between the two stages may have introduced confirmation or acquiescence bias. Awareness that the recommendations were AI-generated may also have influenced the evaluations, although the direction or magnitude of this effect cannot be determined from the present study. The procedure was examined using a single LLM, a fixed prompt, and the validated BMC as its sole organisational input. Only a single response was generated and retained for each case, so the study does not assess the stability of recommendations across repeated LLM outputs, which may vary due to the non-deterministic nature of generative models. The study captured willingness to consider recommendations rather than their subsequent implementation or business outcomes. Future research should examine the procedure across larger and more diverse sets of SMEs, involve multiple decision-makers, and compare alternative models, prompts, and input representations. Following selected

recommendations longitudinally from managerial evaluation through implementation would provide evidence on whether their perceived relevance and feasibility translate into measurable business outcomes.

ACKNOWLEDGEMENT

This research has been conducted as part of the wider research in the project Value Perspectives in Digital Transformation Initiatives (VPiDT), which is funded by the European Union – NextGenerationEU.

Generative AI disclosure. ChatGPT (OpenAI) was used as a supporting tool during the preparation of the manuscript, mainly for proofreading and occasional suggestions on how individual sentences could be phrased more clearly. It was also used to check the reference list for missing or inconsistent entries. The author reviewed all suggestions before incorporating any changes and remains fully responsible for the final manuscript.

REFERENCES

1. Bachmann, N., Thienemann, A.-K., Tüzün, A., Brunner, M., Tripathi, S., Pöchtrager, S., & Jodlbauer, H. (2025). The evolution of the Business Model Canvas for digital sustainability. *Procedia Computer Science*, 253, 1012–1023. <https://doi.org/10.1016/j.procs.2025.01.163>
2. Brunner, M., Thienemann, A.-K., Tripathi, S., Bachmann, N., Tüzün, A., Pöchtrager, S., Warnau, J., & Jodlbauer, H. (2026). An artificial intelligence supported business model innovation initiation and ideation phase. *Procedia Computer Science*, 277, 2753–2762. <https://doi.org/10.1016/j.procs.2026.02.312>
3. Clauss, T., Breier, M., Kraus, S., Durst, S., & Mahto, R. V. (2022). Temporary business model innovation – SMEs' innovation response to the COVID-19 crisis. *R&D Management*, 52(2), 294–312. <https://doi.org/10.1111/radm.12498>
4. Csaszar, F. A., Ketkar, H., & Kim, H. (2024). Artificial intelligence and strategic decision-making: Evidence from entrepreneurs and investors. *Strategy Science*, 9(4), 322–345. <https://doi.org/10.1287/stsc.2024.0190>
5. Doshi, A. R., Bell, J. J., Mirzayev, E., & Vanneste, B. S. (2025). Generative artificial intelligence and evaluating strategic decisions. *Strategic Management Journal*, 46(3), 583–610. <https://doi.org/10.1002/smj.3677>
6. Elsa, D., Indrawati, H., & Caska. (2025). Digital transformation in SMEs: Global maps and trends of research. *Strategy & Leadership*, 53(2), 132–159. <https://doi.org/10.1108/SL-09-2024-0104>
7. Foss, N. J., & Saebi, T. (2017). Fifteen years of research on business model innovation: How far have we come, and where should we go? *Journal of Management*, 43(1), 200–227. <https://doi.org/10.1177/0149206316675927>
8. Jafari-Sadeghi, V., Amoozad Mahdiraji, H., Alam, G. M., & Mazzoleni, A. (2023). Entrepreneurs as strategic transformation managers: Exploring micro-foundations of digital transformation in small and medium internationalisers. *Journal of Business Research*, 154, 113287. <https://doi.org/10.1016/j.jbusres.2022.08.051>
9. Kanbach, D. K., Heiduk, L., Blueher, G., Schreiter, M., & Lahmann, A. (2024). The GenAI is out of the bottle: Generative artificial intelligence from a business model

- innovation perspective. *Review of Managerial Science*, 18(4), 1189–1220.
<https://doi.org/10.1007/s11846-023-00696-z>
10. Kutnjak, A. (2026). *Modificirano platno poslovnoga modela kao instrument samoprocjene spremnosti malih i srednjih poduzeća za digitalnu transformaciju* [Doctoral dissertation, University of Zagreb, Faculty of Organization and Informatics]. Croatian Scientific Bibliography. <https://urn.nsk.hr/urn:nbn:hr:211:771237>
 11. OECD. (2024). *SME digitalisation to manage shocks and transitions: 2024 OECD D4SME survey* (OECD SME and Entrepreneurship Papers No. 62). OECD Publishing. <https://doi.org/10.1787/eb4ec9ac-en>
 12. OECD. (2025). *GenAI and the SME workforce: New survey evidence*. OECD Publishing. <https://doi.org/10.1787/2d08b99d-en>
 13. Osterwalder, A. (2004). The business model ontology: A proposition in a design science approach [Doctoral dissertation, University of Lausanne]. *IRIS*. <https://iris.unil.ch/entities/publication/2946a1c2-6d59-4440-99e7-f768ca26b8d3>
 14. Osterwalder, A., & Pigneur, Y. (2010). *Business model generation: A handbook for visionaries, game changers, and challengers*. John Wiley & Sons.
 15. Rajaram, K., & Tinguely, P. N. (2024). Generative artificial intelligence in small and medium enterprises: Navigating its promises and challenges. *Business Horizons*, 67(5), 629–648. <https://doi.org/10.1016/j.bushor.2024.05.008>
 16. Raisch, S., & Krakowski, S. (2021). Artificial intelligence and management: The automation–augmentation paradox. *Academy of Management Review*, 46(1), 192–210. <https://doi.org/10.5465/amr.2018.0072>
 17. Sosna, M., Trevinyo-Rodríguez, R. N., & Velamuri, S. R. (2010). Business model innovation through trial-and-error learning: The Naturhouse case. *Long Range Planning*, 43(2–3), 383–407. <https://doi.org/10.1016/j.lrp.2010.02.003>
 18. Taksi Deveciyan, M., Alay, H. K., & Keskin, R. (2026). How does the adoption of GenAI affect the speed of strategic decision-making and innovation performance in SMEs? *Economics*, 20(1), 20250191. <https://doi.org/10.1515/econ-2025-0191>
 19. Teece, D. J. (2010). Business models, business strategy and innovation. *Long Range Planning*, 43(2–3), 172–194. <https://doi.org/10.1016/j.lrp.2009.07.003>
 20. Teng, D., Ye, C., & Martinez, V. (2025). Gen-AI's effects on new value propositions in business model innovation: Evidence from information technology industry. *Technovation*, 143, 103191. <https://doi.org/10.1016/j.technovation.2025.103191>
 21. Verhoef, P. C., Broekhuizen, T., Bart, Y., Bhattacharya, A., Dong, J. Q., Fabian, N., & Haenlein, M. (2021). Digital transformation: A multidisciplinary reflection and research agenda. *Journal of Business Research*, 122, 889–901. <https://doi.org/10.1016/j.jbusres.2019.09.022>
 22. Wishah, R., Weshah, S., & Rahahleh, H. (2026). GenAI capability, business model innovation, and business development performance: A moderated mediation framework for SMEs in an emerging market. *Administrative Sciences*, 16(7), 310. <https://doi.org/10.3390/admsci16070310>
 23. Yin, R. K. (2018). *Case study research and applications: Design and methods* (6th ed.). SAGE Publications.

APPENDIX A

Prompt Used for LLM-based Recommendation Generation

The same prompt was used for both case studies. In each case, the validated current-state Business Model Canvas was provided to Claude Sonnet 5 (Anthropic) as an image-based input. The two cases were analysed sequentially within the same new conversation, as described in Section 2.2. Web search and external knowledge retrieval were disabled. The model was instructed to base its analysis exclusively on the information contained in the attached Business Model Canvas and to generate exactly nine recommendations. The prompt reproduced below is presented verbatim as used in both cases.

The attached image contains a validated Business Model Canvas (BMC) representing the current business model of a small or medium-sized enterprise (SME).

Analyse the attached Business Model Canvas and generate recommendations that could support the future development of the company.

Generate exactly three recommendations in each of the following areas:

1. BUSINESS MODEL INNOVATION (BMI)

Propose changes or extensions to how the company creates, delivers, or captures value. Recommendations may address one or more of the nine Business Model Canvas elements.

2. DIGITAL TRANSFORMATION (DT)

Propose applications or improvements of digital technologies, processes, data use, or digital capabilities that could improve the company's operations or its interactions with customers and business partners.

3. AI ADOPTION (AI)

Propose realistic applications of artificial intelligence that could support the company's activities, decision-making, customer interactions, or future development.

For each recommendation provide:

- ID: BMI1-BMI3, DT1-DT3, or AI1-AI3
- Recommendation: a short and specific title
- Description: a concise explanation of the proposed change and how it relates to the current business model
- Expected benefit: the main potential business benefit

Base your analysis exclusively on the information contained in the attached Business Model Canvas.

Recommendations may propose new activities, capabilities, technologies, channels, partnerships, revenue mechanisms, or other business model elements, but the rationale for each recommendation must be explicitly grounded in the current business model.

Do not use or assume external information about the company, its market, competitors, customers, or industry beyond what can reasonably be inferred from the provided Business Model Canvas.

Do not evaluate or rank the recommendations. Do not assess their strategic fit, feasibility, expected business value, or implementation effort. These aspects will be evaluated separately by the company's decision-maker.

Generate exactly nine recommendations in total: three Business Model Innovation recommendations, three Digital Transformation recommendations, and three AI Adoption recommendations.

Present the results as a table with the following columns:
Area | ID | Recommendation | Description | Expected benefit

Note. The prompt was identical for Case A and Case B; only the attached validated Business Model Canvas differed. The generated outputs are reported in the Results section of the manuscript and are therefore not duplicated in this appendix.

APPENDIX B. Individual managerial evaluation scores

ID	Strategic fit	Feasibility	Expected business value	Implementation effort	Decision
A-BMI1	2	2	2	4	No
A-BMI2	3	3	3	4	Yes, with modifications
A-BMI3	4	3	4	3	Yes
A-DT1	4	4	3	2	Yes
A-DT2	3	3	2	3	Yes, with modifications
A-DT3	3	4	4	4	Yes
A-AI1	4	4	5	2	Yes
A-AI2	4	4	4	3	Yes
A-AI3	5	5	4	2	Yes
B-BMI1	5	5	5	5	Yes
B-BMI2	5	5	4	2	Yes
B-BMI3	4	4	4	3	Yes, with modifications
B-DT1	5	4	5	4	Yes
B-DT2	4	4	4	3	Yes, with modifications
B-DT3	5	4	5	3	Yes
B-AI1	5	3	5	4	Yes, with modifications
B-AI2	3	3	3	4	Yes, with modifications
B-AI3	4	4	4	3	Yes, with modifications

Source: Author

Note. All four evaluation criteria were rated on a five-point scale (1 = very low, 5 = very high). For implementation effort, a higher score indicates greater organisational, financial, technological, or human requirements.

Preliminary communication / Prethodno priopćenje

VIDEO MARKETING'S DECADE OF GROWTH AND WHY AI MAKES HUMAN STORYTELLING MORE VALUABLE

ČRTOMIR RASPOR JOSIPOVIČ

University of Maribor
Faculty of Organizational Sciences
Kidričeva 55a, 4000 Kranj, Slovenia
crtomir.raspor@student.um.si

MIHA MARIČ

University of Maribor
Faculty of Organizational Sciences
Kidričeva 55a, 4000 Kranj, Slovenia
miha.maric@um.si

ABSTRACT

Marketing communication has shifted from static, print-based formats toward dynamic, video-driven content, and generative artificial intelligence is now accelerating that shift into hyper-personalized engagement tied to the buyer's journey. This paper examines how the dual transformation reshapes effective marketing communication and asks why human storytelling keeps its value as AI scales content production. Drawing on a desk-based synthesis of recent empirical and conceptual research alongside current industry data, it traces the migration of advertising investment toward short-form video, the role of narrative transportation in capturing attention under conditions of ad avoidance, and the democratization of content creation enabled by generative AI. The analysis shows a central paradox: the same technology that lets small teams produce at agency scale compresses creative output toward the mean, flooding the information environment while eroding distinctiveness. The paper argues that authentic human narrative becomes scarcer, and therefore more valuable, precisely as machine-generated content becomes abundant. It concludes that storytelling, founder-led authenticity, and consumer trust constitute the durable sources of differentiation in an AI-saturated market and identifies directions for future research.

KEYWORDS: marketing, storytelling, generative artificial intelligence, brand authenticity, customer journey, content personalization, content marketing, creator economy

1. INTRODUCTION

Marketing communication has changed. Advertising investment that once flowed to print and static display now concentrates in dynamic, video-first formats: in the United States, digital video was the fastest-growing advertising format of 2024, rising 19.2% to USD 62.1 billion and capturing 24% of all internet advertising revenue (Interactive Advertising Bureau [IAB] & PwC, 2025, p. 6). The underlying logic reflects what Davenport and Beck (2001) identified as

the defining scarcity of modern markets: attention, not information or media inventory, has become the resource that audiences ration. Where the cost of receiving an advertisement outweighs its perceived value, audiences disengage or actively avoid it (Cho & Cheon, 2004, p. 89). Content marketing appeared as the strategic response, an inbound alternative to interruption (Holliman & Rowley, 2014), and video appears to have become its dominant vehicle because, unlike static formats, narrative can sustain attention over time.

A second, faster shift now overlays the first. Generative AI has moved from novelty to operational infrastructure in marketing, reducing the cost and technical skill once needed for professional content production and enabling small teams to work at scales previously associated with dedicated production budgets. Yet the same democratization that expands production also flattens it: AI-assisted content tends to converge toward the mean, lifting individual output while narrowing collective novelty (Doshi & Hauser, 2024). Abundance and sameness arrive together.

This paper argues that storytelling is the differentiator that resolves this tension, and that AI raises its value rather than diminishing it. As production becomes cheap, abundant, and homogeneous, authentic human narrative becomes comparatively scarce, and scarcity is the precondition for competitive advantage. Although the productivity effects of generative AI and the persuasive effects of narrative are each well documented, the two literatures have developed largely in parallel, and what happens to the competitive value of human storytelling once AI-generated content becomes abundant is still unresolved. The research aim is to trace how the print-to-video shift and the later AI acceleration have reshaped the conditions for effective marketing communication, and to show why human creative vision keeps primacy in a hyper-personalized, AI-saturated content environment.

The paper draws on a structured desk review of peer-reviewed literature published between 2013 and 2026, across marketing, consumer behaviour, and information systems journals, supplemented by industry benchmarks from the IAB, McKinsey Global Institute, and comparable institutions. Sources were selected for empirical or theoretical relevance to three core themes: the structural shift from print to video, storytelling as a mechanism of persuasion, and AI-enabled content democratization.

Searches were run primarily in ScienceDirect, with targeted searches in Emerald Insight, SAGE Journals, SpringerLink and Taylor & Francis Online, combining keywords on video marketing and short-form video, on storytelling, narrative transportation and brand authenticity, and on generative artificial intelligence and AI-generated content. Studies were included when they reported empirical findings or set out conceptual frameworks in marketing, consumer behaviour or information systems outlets; non-peer-reviewed commentary was excluded. Industry data serve as market benchmarks rather than as evidence for theoretical claims.

The argument continues across four sections. Beginning with the literature review, we synthesize evidence across three pillars: the structural move from print to video, storytelling as the mechanism of persuasion under conditions of avoidance, and AI-driven democratization alongside its attendant creativity deficit. A then-and-now comparison follows, documenting the measurable distance between a roughly 2014 baseline and the present. The discussion then maps hyper-personalization onto the buyer's journey, develops the tension between scale and quality, and examines founder-led narrative as a defensible competitive position. The conclusion combines the central argument and shows directions for future research.

2. LITERATURE REVIEW

The shift from print to video in marketing communication reflects a structural change in how attention is won. Attention, rather than information, is now the scarce resource that marketing competes for (Davenport & Beck, 2001), and investment has followed accordingly, with digital video becoming the largest and fastest-growing advertising category in the United States (IAB & PwC, 2025). Audiences actively avoid advertising that obstructs what they came to do, crowds the screen, or has disappointed them before, a set of avoidance behaviours documented formally over two decades ago (Cho & Cheon, 2004, p. 89). Video addresses this at the level of form: its sequential, time-based structure sustains engagement that static text and display rarely match. Short-form video has become the dominant emerging format, driven by mobile-first consumption and algorithmic amplification that match content to inferred interest at scale (Zhang et al., 2025). Research on TikTok converges on what holds attention within this format: trustworthiness, expertise, and attractiveness raise purchase behaviour, while authenticity and brand heritage operate non-linearly (Meng et al., 2024), and engagement tracks performance expectancy, entertainment, and tie strength as much as overt selling (Xiao et al., 2022). The medium's technical features matter independently, as audiovisual attributes such as cadence, colourfulness, and colloquial delivery each predict engagement (Zhang et al., 2025). Who produces the content shapes its effect as well: user-generated content correlates more strongly with awareness and satisfaction, while firm-generated content, and its vividness in particular, drives consideration and purchase intent (Colicev et al., 2019). Format competition is thus also a contest over narrative control. The two are not strictly comparable: Meng et al. (2024) relate source characteristics to self-reported purchase behaviour in one national market, while Xiao et al. (2022) model engagement intention, so the differing weight given to entertainment and to credibility may partly reflect measurement. Neither tests whether the effects hold once much of the feed is machine-generated.

When avoidance is the default response to marketing messages, narrative is the form that most reliably circumvents it. Content marketing reframes the exchange as an inbound one, earning attention by offering something useful or engaging rather than interrupting for it (Holliman & Rowley, 2014); storytelling is what converts that delivered value into persuasion. The transportation-imagery tradition explains this mechanism: when audiences are absorbed into a story, they counter-argue less and accept the embedded message more readily, an effect synthesized across 132 effect sizes from 76 studies (Van Laer et al., 2013). Storytelling thus operates as a functional persuasion mechanism under conditions of audience resistance. Recent work extends the mechanism to social platforms, showing that character-driven narratives raise narrative transportation and downstream behaviour, and that the effect strengthens when the messenger's image aligns with the message, what Tan et al. (2026) describe as an influencer-message congruity effect. The persuasive force of narrative is closely tied to perceived authenticity. When audiences learn that content was generated by AI, perceived brand authenticity falls and follower reactions turn negative, though the effect softens when AI assists rather than replaces human creation (Brüns & Meißner, 2024). Authenticity also explains why individual creators often outperform brands as narrators. Parasocial relationships, more than expertise or attractiveness alone, drive purchase intention in influencer marketing (Masuda et al., 2021), and the creator has developed into a recognizable entrepreneurial form, what Edeling and Wies (2024) call the creatrepreneur, in which personal narrative and brand identity combine into a defensible asset. The reason narrative carries this weight is, again, the scarcity of attention: in a crowded environment, audiences filter, prioritize, and manage cognitive load (Shahrzadi et al., 2024), and narrative is the format that earns a hearing.

Where the first two pillars concern what audiences attend to and why, the third concerns who can now afford to compete for that attention. Generative AI produces content judged more personally relevant than that of earlier digital technologies, while compressing the cost and time of production (Kshetri et al., 2023). This fits a strategic division of labour described by Huang and Rust (2020), in which mechanical AI standardizes, thinking AI personalizes, and feeling AI manages relationships. The capability now extends to visual and video output. In controlled comparisons, the strongest text-to-image models produced marketing imagery that surpassed human-made images on quality, realism, and aesthetics (Hartmann et al., 2024). In a field test, the best AI-generated banner achieved a click-through rate of 0.80% against 0.53% for a professional stock photo, at a fraction of the cost: an advertiser could generate 225 images for the price of one stock photo (Hartmann et al., 2024). Adoption reflects these gains. In 2024, 65% of organizations reported regularly using generative AI, with the steepest increase in marketing and sales, where reported use more than doubled in a single year (McKinsey & Company, 2024).

The distributional implications are more consequential than the productivity gains alone. Where prior technologies augmented execution, generative AI redistributes creative and economic capabilities once concentrated in agencies, allowing a single person to perform work that previously required a large team; in the process, agency value shifts from execution toward strategic expertise (Wahid et al., 2025). This is the democratization argument in its strongest empirical form, and it comes with a corresponding risk. Generative AI raises individual output but compresses collective variety: stories written with AI assistance are rated more creative yet resemble one another more closely than human-only work, a social dilemma in which each producer gains while the shared pool of novelty narrows (Doshi & Hauser, 2024). On the reception side, consumers' trust and perceived humanness govern their response to AI-generated advertising (Jung et al., 2025), and disclosed AI authorship can erode perceived authenticity (Brüns & Meißner, 2024), while cultural, ethical, and strategic barriers keep adoption uneven across organizations (Volkmar et al., 2022). The technology therefore expands productive capacity and contracts creative differentiation simultaneously.

This sits alongside Hartmann et al. (2024) rather than against it, since the two studies measure different objects: the quality of the stimulus and the attribution of its source. What matters competitively is therefore whether audiences accept the origin of the content, not whether the output is good enough. Table 1 summarises the three strands, the studies that carry them, and what each leaves open.

Table 1. Overview of the reviewed literature by thematic pillar

Pillar	Key studies	Established	Left open
From print to video	Zhang et al. (2025); Xiao et al. (2022)	Investment and attention have moved to short-form video; audiovisual features predict engagement.	Platform-specific samples; untested where feeds are largely AI-generated.
Storytelling and authenticity	Van Laer et al. (2013); Masuda et al. (2021)	Narrative transportation lowers resistance; parasocial bonds drive intention.	Evidence predates AI-saturated feeds; stated intention rather than behaviour.
AI democratization	Wahid et al. (2025); Doshi & Hauser (2024)	Production cost collapses; individual output rises while collective variety narrows.	Narrow formats; long-run market effects of

			homogenization unmeasured.
Reception of AI content	Brüns & Meißner (2024); Jung et al. (2025)	Disclosed AI authorship lowers perceived authenticity; trust mediates response.	Short-term exposure; persistence as disclosure normalizes unknown.

Source: Authors, based on the reviewed literature.

3. THEN & NOW

The clearest indicator of the decade's shift is the AI adoption curve. Organizational AI adoption hovered near 50% for roughly six years before rising to 72% by early 2024, while regular use of generative AI reached 65%, up from approximately one-third just a year earlier (McKinsey & Company, 2024). Marketing and sales recorded the steepest increase: reported generative AI use more than doubled in that single year, and 67% of organizations expected to raise AI investment over the following three years (McKinsey & Company, 2024). Against a 2014 baseline, the contrast is categorical rather than incremental. AI in marketing was then treated largely as a prospective capability; frameworks formalizing its strategic role appeared only at the turn of the decade (Huang & Rust, 2020). The economic stakes reflect that trajectory: generative AI is projected to add USD 2.6 to 4.4 trillion annually across analysed use cases, with roughly three-quarters of that value concentrated in four functions including marketing and sales, and marketing-specific productivity gains estimated at 5 to 15 percent of total marketing spending (McKinsey & Company, 2023).

These macro figures rest on a collapse in production economics. In content marketing agencies, generative AI has shifted work that once required a full team to tasks a single person can now execute, compressing cost structures and redirecting agency value toward expertise (Wahid et al., 2025, p. 7); industry forecasts cited in the same study anticipate price reductions of up to 20% for marketing-agency services (Wahid et al., 2025, p. 11). The visual case is starker: a campaign image produced with a leading text-to-image model cost a small fraction of a professional alternative, allowing an advertiser to generate 225 images for the price of a single stock photo (Hartmann et al., 2024).

Cheaper production has multiplied content volume faster than attention can absorb it. Practitioners report producing two to three times their prior content output with no proportional growth in readership (Wahid et al., 2025, p. 7); this volume increase contributes to structural content saturation, a condition the information-overload literature links to poorer decisions and cognitive strain (Shahrzadi et al., 2024). The same abundance reduces distinctiveness, as AI-assisted output has been associated with measurable increases in inter-text similarity (Doshi & Hauser, 2024). The behavioural tendency to avoid advertising is not new; ad avoidance was modelled as early as 2004 (Cho & Cheon, 2004, p. 89), but platform scale has since amplified both the volume to be avoided and the premium on content that resists it.

Short-form video is the current arena for this contest. By December 2022, short-video app users in China had reached 1,012 million, or 90.5% of the country's internet users, and global video-ad spending was projected to exceed USD 76 billion in 2023 (Meng et al., 2024). In the United States, digital video reached USD 62.1 billion in 2024, a 19.2% annual increase that made it the fastest-growing format and 24% of all internet advertising revenue. That total sits within a

five-year climb from USD 139.8 billion in 2020 to USD 258.6 billion in 2024 across all digital ad revenue (IAB & PwC, 2025).

Personalization marks the final dimension of change. The 2016 articulation of the customer journey treated experience as a sequence of touchpoints managed across pre-purchase, purchase, and post-purchase stages (Lemon & Verhoef, 2016). AI-enabled personalization now operates within those same stages as continuous profiling, navigation, nudging, and retention (Gao & Liu, 2022). Its effect on engagement, however, is not direct: it works through consumer trust and perceived usefulness as mediating variables (Teepapal, 2024).

4. DISCUSSION AND IMPLICATIONS

The customer journey has become the organizing framework for AI-enabled marketing. What was once a conceptual sequence of touchpoints managed across pre-purchase, purchase, and post-purchase stages (Lemon & Verhoef, 2016) is now personalized continuously through profiling, nudging, and retention mechanisms (Gao & Liu, 2022). Personalization operates at both the message and the distribution level: recommendation algorithms are tuned to the individual, determining which content reaches a given consumer, in what sequence, and when they are most receptive. Even so, personalization does not move consumers on its own. Its effect on engagement is conditional on trust and perceived usefulness rather than on targeting precision alone (Teepapal, 2024). This shapes how content should be matched to funnel stage. User-generated content correlates more strongly with brand awareness and satisfaction, while firm-generated content and its visual vividness drive consideration and purchase intent (Colicev et al., 2019). The implication is a practical division: creator and user stories are better suited to the top of the funnel, where trust is still forming, while brand-controlled narrative converts further down. AI can make this matching more granular and scalable, but the trust each stage depends on is earned through perceived narrative authenticity, not through the targeting system itself.

The same capability that makes content production scalable tends to dilute its competitive value. Generative AI allows a single person to produce what once required a full team (Wahid et al., 2025, p. 7), and leading image generation models now match or surpass professional-quality visual output on measurable criteria (Hartmann et al., 2024). As production becomes cheap and widely accessible, however, content volume is rising two- to threefold with no corresponding growth in audience attention (Wahid et al., 2025, p. 7), and AI-assisted output is converging toward similar forms (Doshi & Hauser, 2024). When competent content is abundant, technical competence stops differentiating. Value shifts toward what resists imitation: narrative grounded in real, distinctive identity that generative models replicate poorly, and that audiences reward differently, given that disclosed AI authorship tends to reduce perceived brand authenticity (Brüns & Meißner, 2024). This suggests that AI is most useful on the mechanical, high-volume layers of marketing work, with human creative judgment reserved for the narrative layer where differentiation is won (Huang & Rust, 2020). The reading developed here is the authors' own interpretation of the evidence summarised in Table 1: disclosed machine authorship acts on the link between narrative and perceived authenticity rather than on production quality, and it is there that competitive advantage is now decided.

When authentic narrative is the scarce competitive resource, its most defensible form is tied to a specific person. Research on parasocial relationships suggests that the bond between an audience and a creator can drive purchase intention more strongly than perceived expertise or

physical attractiveness (Masuda et al., 2021), and the creator economy has increasingly institutionalized this dynamic: personal narrative and brand identity merge into a single asset that can be owned and built upon over time (Edeling & Wies, 2024). A founder or creator story is difficult for competitors to replicate because it is non-transferable. It draws credibility from a real biography that generative models cannot authentically author, and whose synthetic simulation carries the authenticity penalty associated with disclosed AI-generated content (Brüns & Meißner, 2024). The pattern is visible in the growth of influencer-founded consumer brands and expert-led personal brands, where a single credible voice converts into durable market share. For small teams, this is practically significant. The same AI-enabled democratization that allows one person to produce at near-agency scale (Wahid et al., 2025, p. 7) also allows a personal narrative to reach a mass audience without traditional distribution intermediaries. Strategically, this suggests concentrating scarce human creative effort on the story that only the firm's own people can tell, while using AI for the scalable remainder.

As generative tools saturate the content environment with fluent but interchangeable material, the signal becoming genuinely scarce is evidence of a real person behind the message. Audiences tend to seek what machine-produced content cannot credibly supply: lived experience, a particular perspective, and the sense of engaging with another person. Research on narrative transportation suggests that absorption into a credible story deepens persuasion (Van Laer et al., 2013), and this effect appears stronger when the storyteller's identity is congruent with the message (Tan et al., 2026). In a market flooded with AI-generated content, the source of credibility shifts. Trust, rather than reach or production quality, appears to become the primary differentiator, and it tends to accrue to people and brands that audiences can identify as authentically human, since disclosed machine authorship undermines the perceived authenticity on which persuasion depends (Brüns & Meißner, 2024). Personal and founder-led brands are well positioned here because their narratives are inseparable from a real person whose presence audiences can follow and verify over time. The decisive question is therefore who maintains a credible human relationship with an audience, not who can produce the most content. Brands that treat storytelling as the part of marketing that only people can do and use AI for the production and distribution work around it, are likely to be better placed as synthetic content becomes the norm.

5. CONCLUSION

Generative AI has lowered the cost of producing content toward zero, extending the logic of the print-to-video transition to its conclusion. The research aim was to explain why human creative vision retains primacy in this environment, and the evidence supports a clear answer. Democratization is real: small teams and solo creators can now operate at a scale and quality once reserved for agencies. But abundance is self-cancelling as a source of advantage. When competent content is universal and converges toward sameness, value migrates to what cannot be mass-produced: authentic, person-anchored narrative that audiences trust and that disclosed machine authorship measurably devalues. Storytelling therefore functions as the complement to AI. AI is most productively deployed on the mechanical and high-volume layers of marketing work, freeing human judgment for the narrative layer where differentiation is decided. For practitioners, the implication is to treat generative AI as a production engine and human storytelling as the creative core, building trust through founder-led and creator-led narratives that competitors cannot replicate. Future research should assess these propositions empirically by measuring how audiences discriminate between human and AI-authored narrative over time, how the authenticity premium behaves as synthetic content normalizes, and how founder-led

brands sustain parasocial trust at scale. As production becomes effectively infinite, the scarce and decisive resource is a story worth believing.

This study has clear limits. It is a desk review without primary data, so its claims are argued rather than tested, and sources were selected purposively rather than under a formal protocol. The evidence base is mostly English-language and drawn from Western and Chinese markets, the industry benchmarks are largely United States-centred and shifting category definitions in industry reporting weaken like-for-like comparison across the decade. Three studies would take the argument further: an experiment varying disclosed authorship across funnel stages, a longitudinal design tracking whether the authenticity penalty decays as synthetic content becomes normal, and firm-level data linking founder-led narrative to customer acquisition cost.

REFERENCES

1. Brüns, J. D., & Meißner, M. (2024). Do you create your content yourself? Using generative artificial intelligence for social media content creation diminishes perceived brand authenticity. *Journal of Retailing and Consumer Services*, 79, 103790. <https://doi.org/10.1016/j.jretconser.2024.103790>
2. Cho, C.-H., & Cheon, H. J. (2004). Why do people avoid advertising on the Internet? *Journal of Advertising*, 33(4), 89–97. <https://www.jstor.org/stable/4189279>
3. Colicev, A., Kumar, A., & O'Connor, P. (2019). Modeling the relationship between firm and user generated content and the stages of the marketing funnel. *International Journal of Research in Marketing*, 36(1), 100–116. <https://doi.org/10.1016/j.ijresmar.2018.09.005>
4. Davenport, T. H., & Beck, J. C. (2001). The attention economy. *Ubiquity*, 2001(May), 1. <https://doi.org/10.1145/376625.376626>
5. Doshi, A. R., & Hauser, O. P. (2024). Generative AI enhances individual creativity but reduces the collective diversity of novel content. *Science Advances*, 10(28), eadn5290. <https://doi.org/10.1126/sciadv.adn5290>
6. Edeling, A., & Wies, S. (2024). Embracing entrepreneurship in the creator economy: The rise of creatpreneurs. *International Journal of Research in Marketing*, 41(3), 436–454. <https://doi.org/10.1016/j.ijresmar.2024.07.003>
7. Gao, Y., & Liu, H. (2022). Artificial intelligence-enabled personalization in interactive marketing: a customer journey perspective. *Journal of Research in Interactive Marketing*, 17(5), 663–680. <https://doi.org/10.1108/jrim-01-2022-0023>
8. Hartmann, J., Exner, Y., & Domdey, S. (2024). The power of generative marketing: Can generative AI create superhuman visual marketing content? *International Journal of Research in Marketing*, 42(1), 13–31. <https://doi.org/10.1016/j.ijresmar.2024.09.002>
9. Holliman, G., & Rowley, J. (2014). Business to business digital content marketing: marketers' perceptions of best practice. *Journal of Research in Interactive Marketing*, 8(4), 269–293. <https://doi.org/10.1108/jrim-02-2014-0013>
10. Huang, M., & Rust, R. T. (2020). A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science*, 49(1), 30–50. <https://doi.org/10.1007/s11747-020-00749-9>
11. Interactive Advertising Bureau, & PwC. (2025). IAB internet advertising revenue report: Full year 2024. https://www.iab.com/wp-content/uploads/2025/04/IAB_PwC-Internet-Ad-Revenue-Report-Full-Year-2024.pdf
12. Jung, T., Koghut, M., Lee, E., & Kwon, O. (2025). Artificial creativity in luxury advertising: How trust and perceived humanness drive consumer response to AI-

- generated content. *Journal of Retailing and Consumer Services*, 87, 104403.
<https://doi.org/10.1016/j.jretconser.2025.104403>
13. Kshetri, N., Dwivedi, Y. K., Davenport, T. H., & Panteli, N. (2023). Generative artificial intelligence in marketing: Applications, opportunities, challenges, and research agenda. *International Journal of Information Management*, 75, 102716.
<https://doi.org/10.1016/j.ijinfomgt.2023.102716>
14. Lemon, K. N., & Verhoef, P. C. (2016). Understanding customer experience throughout the customer journey. *Journal of Marketing*, 80(6), 69–96.
<https://doi.org/10.1509/jm.15.0420>
15. Masuda, H., Han, S. H., & Lee, J. (2021). Impacts of influencer attributes on purchase intentions in social media influencer marketing: Mediating roles of characterizations. *Technological Forecasting and Social Change*, 174, 121246.
<https://doi.org/10.1016/j.techfore.2021.121246>
16. McKinsey & Company. (2023). *The economic potential of generative AI: The next productivity frontier*. <https://www.mckinsey.com/capabilities/tech-and-ai/our-insights/the-economic-potential-of-generative-ai-the-next-productivity-frontier>
17. McKinsey & Company. (2024). *The state of AI in early 2024: Gen AI adoption spikes and starts to generate value*. <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai-2024>
18. Meng, L., Kou, S., Duan, S., & Bie, Y. (2024). The impact of content characteristics of Short-Form video ads on consumer purchase Behavior: Evidence from TikTok. *Journal of Business Research*, 183, 114874. <https://doi.org/10.1016/j.jbusres.2024.114874>
19. Shahrzadi, L., Mansouri, A., Alavi, M., & Shabani, A. (2024). Causes, consequences, and strategies to deal with information overload: A scoping review. *International Journal of Information Management Data Insights*, 4(2), 100261.
<https://doi.org/10.1016/j.jjimei.2024.100261>
20. Tan, S. Z., Yang, L., Loo, W. H., & Chalke, A. (2026). Stories that matter: the effects of narrative transportation and influencer-message congruity on prosocial behavior. *Journal of Business Research*, 208, 116051. <https://doi.org/10.1016/j.jbusres.2026.116051>
21. Teepapal, T. (2024). AI-driven personalization: Unraveling consumer perceptions in social media engagement. *Computers in Human Behavior*, 165, 108549.
<https://doi.org/10.1016/j.chb.2024.108549>
22. Van Laer, T., De Ruyter, K., Visconti, L. M., & Wetzels, M. (2013). The Extended Transportation-Imagery Model: A Meta-Analysis of the antecedents and consequences of consumers' narrative transportation. *Journal of Consumer Research*, 40(5), 797–817.
<https://doi.org/10.1086/673383>
23. Volkmar, G., Fischer, P. M., & Reinecke, S. (2022). Artificial Intelligence and Machine Learning: Exploring drivers, barriers, and future developments in marketing management. *Journal of Business Research*, 149, 599–614.
<https://doi.org/10.1016/j.jbusres.2022.04.007>
24. Wahid, R., Mero, J., & Ritala, P. (2025). Technology-enabled democratization: Impact of generative AI on content marketing agencies. *Industrial Marketing Management*, 131, 1–16. <https://doi.org/10.1016/j.indmarman.2025.09.007>
25. Xiao, L., Li, X., & Zhang, Y. (2022). Exploring the factors influencing consumer engagement behavior regarding short-form video advertising: A big data perspective. *Journal of Retailing and Consumer Services*, 70, 103170.
<https://doi.org/10.1016/j.jretconser.2022.103170>
26. Zhang, Z., Qiu, K., & Ye, Y. (2025). Influence of audiovisual features of short video advertising on consumer engagement behaviors: Evidence from TikTok. *Journal of Business Research*, 201, 115662. <https://doi.org/10.1016/j.jbusres.2025.115662>

AWARENESS OF FASHION CONSUMPTION CONSEQUENCES AND SUSTAINABLE CLOTHING PRACTICES

LARISA HRUSTEK

University of Zagreb
Faculty of Organization and Informatics
Pavlinska 2, 42000 Varaždin, Croatia
lhrustek@foi.unizg.hr

ANA KUTNJAK

University of Zagreb
Faculty of Organization and Informatics
Pavlinska 2, 42000 Varaždin, Croatia
akutnjak@foi.unizg.hr

KRISTINA MARŠIĆ

University of Zagreb
Faculty of Textile Technology
Prilaz baruna Filipovića 28a, 10000 Zagreb, Croatia
kristina.marsic@ttf.unizg.hr

ABSTRACT

The fashion industry is characterized by rapidly changing trends, frequent introduction of new collections, and increasing accessibility of clothing, particularly through digital channels. These developments contribute to challenges such as overproduction and overconsumption, intensive resource use, textile waste, environmental pollution, greenhouse gas emissions, and unfavorable working conditions. Addressing these challenges requires changes not only in production practices but also in consumer behaviour. Accordingly, this study examines consumers' clothing purchasing habits, their awareness of the environmental, social, and economic impacts of the fashion industry, and the relationship between awareness and sustainable clothing-related behaviour. Primary data were collected using an adapted questionnaire based on a previously validated measurement instrument and relevant literature. Scale reliability and validity were assessed using Cronbach's alpha and exploratory factor analysis, while the research hypotheses were tested using Spearman's correlation analysis. The findings indicate that fast fashion purchasing remains prevalent, while sustainability plays a secondary role in clothing choices. Nevertheless, higher environmental, social, and economic awareness was generally associated with more sustainable behaviour, particularly reduced purchasing, sustainable clothing use and care, and practices extending clothing's useful life. However, the strength and statistical significance of these relationships varied across the examined awareness and behavioural dimensions.

KEYWORDS: clothing purchasing habits, fashion consumption, consumer behaviour, circular economy, clothing disposal, textile waste, sustainable consumption

1. INTRODUCTION

Sustainability encompasses environmental protection, responsible resource use, fair treatment of human resources, the production of healthy and high-quality products, and long-term economic viability. The development of the concept of sustainable development represents a response to increasingly pronounced environmental, social, and economic challenges arising from globalization and the continuous growth of production and consumption. These trends place increasing pressure on limited natural resources, contribute to environmental degradation, and raise concerns about the social and economic consequences of current production and consumption patterns. Such challenges are particularly evident in industries characterized by high production volumes, intensive resource use, and rapidly changing consumption patterns, among which the fashion industry has gained increasing attention.

The fashion industry represents one of the globally significant economic sectors, but at the same time, it is a sector that exerts considerable pressure on the environment. Particular attention is given to the so-called fast fashion concept, which is based on accelerated production cycles, the frequent development of new collections, and the promotion of short-term use and wear of clothing products. Such a business model contributes to an increase in the volume of production and consumption, encourages patterns of excessive consumption and frequent disposal of clothing, and contributes to the problem of textile waste accumulation.

Globally, approximately 92 million tonnes of textile waste are generated annually. At the same time, clothing production doubled between 2000 and 2015, while the period of use of clothing items decreased by 36% (United Nations Environment Programme, 2025). These figures highlight a growing imbalance between the increasing production of clothing and its decreasing period of use, contributing to the generation of substantial amounts of textile waste. This trend poses a significant challenge to the sustainability of the fashion industry.

Based on the Sustainable Development Goals (2015), fast fashion is particularly related to SDG 12 – Responsible Consumption and Production (United Nations, Department of Economic and Social Affairs, n.d.-d), which promotes sustainable production and consumption patterns by reducing resource exploitation, waste, and the negative impacts of production processes. Fast fashion contradicts these principles through its “produce more, sell more, and consume more” model, which encourages frequent purchases and short periods of clothing use. This highlights the need to shift from the linear “take–make–use–dispose” model towards a circular model based on longer use, repair, reuse, and recycling (Shamsuzzaman et al., 2025). Fast fashion is also linked to several other SDGs. In relation to SDG 8 – Decent Work and Economic Growth (United Nations, Department of Economic and Social Affairs, n.d.-c), the fashion industry employs more than 90 million people but faces challenges related to low wages, unsafe working conditions, insufficient worker protection, and informal and temporary employment, with women being particularly vulnerable (International Labour Organization, 2025). This also relates to SDG 5 – Gender Equality (United Nations, Department of Economic and Social Affairs, n.d.-a), as women represent a large proportion of the garment and textile workforce and are particularly represented in vulnerable and lower-paid segments of the production chain (International Labour Organization, n.d.). The environmental impacts of fast fashion are further associated with SDG 13 – Climate Action (United Nations, Department of Economic and Social Affairs, n.d.-e), as the textile sector accounts for an estimated 2 – 8% of global greenhouse gas emissions (UNEP, 2025). Similarly, SDG 6 – Clean Water and Sanitation (United Nations, Department of Economic and Social Affairs, n.d.-b), is particularly relevant due to the intensive use of water in fibre production, dyeing, and finishing processes, estimated at approximately

215 billion litres annually. Fast fashion is also associated with SDG 14 – Life Below Water (United Nations, Department of Economic and Social Affairs, n.d.-f), as the textile sector contributes approximately 9% of annual microplastic pollution in the oceans (UNEP, 2025). Finally, fast fashion is related to SDG 15 – Life on Land (United Nations, Department of Economic and Social Affairs, n.d.-g), since the intensive use of natural resources, chemicals, and water can negatively affect ecosystems, biodiversity, and soil and water quality.

The aim of this study is to examine the purchasing habits of consumers in the Republic of Croatia and to determine their level of awareness of sustainability issues related to the fashion industry, as well as the relationship between such awareness and sustainable clothing practices. The study seeks to analyse the frequency and patterns of clothing purchases, the factors influencing purchasing decisions, and consumers' attitudes towards fast and sustainable fashion. Furthermore, the study examines the extent to which consumers consider the environmental, social, and economic aspects of clothing production when making purchasing decisions.

Particular attention is given to sustainable consumer practices, including extending the useful life of clothing items, reuse, purchasing second-hand clothing, repairing clothing, donating clothing, and the appropriate disposal of textile waste. Based on the collected data, the research aims to determine whether there is a relationship between the level of sustainability awareness and actual consumer behaviour, namely their attitudes and actual purchasing habits.

2. THEORETICAL BACKGROUND

Clothing purchasing habits result from the interplay of personal, economic, social, and market-related factors. Fashion is no longer viewed solely in terms of its basic function but also represents a means of expressing identity, social status, personality, and lifestyle (Putra et al., 2026). Personal values and consumer characteristics therefore play an important role in shaping consumption. The need for uniqueness, materialism, impulsiveness, and fashion consciousness are associated with consumer behaviour in the context of fast fashion. Low prices enable consumers to purchase larger quantities of products, while rapidly changing styles appeal to consumers who follow trends and use clothing as a means of self-expression (Olivar Aponte et al., 2024). Impulsiveness further reduces the ability to control purchasing urges, while exposure to visually appealing promotions and emotionally engaging messages may increase the likelihood of unplanned purchases (Makuku & Suwitho, 2026; Tumangger & Munthe, 2025).

Digitalization has further transformed the way consumers discover, evaluate, and purchase clothing. Social media influence consumer attitudes, purchase intentions, and final purchasing decisions through information sharing, recommendations, and brand engagement (Alalwan et al., 2017), while ratings, reviews, recommendations, and online communities contribute to building consumer trust and purchase intentions (Chanillo, 2026; Hajli, 2015). Brand awareness and brand image also shape consumer preferences, purchasing decisions, and loyalty (Barreda et al., 2015; Büyükdağ, 2021; Persson, 2010; Song et al., 2019). Influencers occupy a particularly important position in the digital environment, as their recommendations and electronic word-of-mouth communication can influence the attitudes and decisions of their followers (Aydin & Takva, 2026; Nkominopondo et al., 2025; Zhang & Caverlee, 2019). Their influence has also been identified in clothing purchasing behaviour (Dehyadegari et al., 2025), while the attractiveness, credibility, and expertise of influencers who promote sustainability

have been identified as predictors of sustainable clothing purchase intentions (Cavender & Lee, 2018; Chan et al., 2025; Londoño-Bedoya et al., 2025).

The development of fast fashion has further transformed consumption patterns. Fashion cycles have accelerated considerably, and instead of the traditional two annual collections, many mini-collections are now introduced to the market (Domingos et al., 2022). Affordability, responsiveness to trends, and rapid product turnover particularly encourage consumption among younger consumers (Hsu et al., 2026). Purchasing decisions are not exclusively rational but are also influenced by emotional impulses (le Roux et al., 2026), brand identification, and peer influence (Hsu et al., 2026). At the same time, alternative consumption patterns are emerging, with vintage and second-hand clothing receiving increasing attention (Butler, 2026; Cervellon et al., 2012; Machado et al., 2019; Tportal, 2026). Motivations for purchasing second-hand clothing include financial benefits, favorable prices, access to brands, quality, durability, and originality, as well as environmental and social considerations (Kuupole et al., 2025; Machado et al., 2019).

The growing consumption of clothing simultaneously raises the issue of consumers' awareness of its broader consequences. Sustainability in the textile and clothing industry encompasses environmental, social, and economic dimensions, with impacts occurring throughout the production, use, and end-of-life stages of a product's life cycle (Masnec et al., 2026). Environmental problems are associated, among other factors, with production processes that harm the environment, increasing amounts of clothing waste, and excessive resource consumption (Park & Lee, 2021). The social dimension includes issues related to the working conditions of garment workers, ethical concerns associated with production, the use of animal fur, and broader cultural aspects of consumption (Park & Lee, 2021). The economic dimension is also reflected in consumer decisions, for example, through the importance of price, value, and financial benefits associated with the purchase, sale, and reuse of clothing (Joung & Park-Poaps, 2013; Machado et al., 2019).

However, awareness of these issues does not necessarily translate into sustainable behaviour. Cervellon et al. (2012) found that the purchase of vintage and second-hand clothing is not necessarily directly driven by environmental awareness and highlighted a potential gap between what consumers consider desirable and what they actually intend to do. Consumers may recognize the importance of recycling, reuse, and responsible clothing disposal without their actual purchasing habits being equally sustainable. Sustainable consumption is therefore shaped not only by rational consideration of consequences but also by emotions, social norms, perceived behavioural control, and previously established habits (He & Hu, 2026).

Sustainable practices can therefore be considered across different stages of the clothing life cycle: purchasing, use, and disposal. At the purchasing stage, more sustainable patterns include reducing the amount of clothing purchased, choosing higher-quality and more durable products, and purchasing second-hand or vintage clothing (Kelleher, 2026; Park & Lee, 2021). The use of second-hand clothing, the purchase of vintage products, and clothing rental contribute to avoiding resource waste and disrupting the cycle of excessive consumption of new products (Park & Lee, 2021). Second-hand fashion can thus extend product life cycles and reduce textile waste, although concerns regarding hygiene, quality, and social perceptions may represent barriers to its adoption (Silva et al., 2021; Sinh, 2026).

Finally, when clothing is no longer needed, consumers can choose several alternatives to discarding it, including donation, reuse, exchange, resale, and recycling (Joung & Park-Poaps,

2013). Digital platforms additionally enable the direct resale or exchange of second-hand clothing between consumers. Such practices are also increasingly being incorporated into the business models of fashion companies. Examples include programs for clothing take-back, repair, rental, resale, donation, and recycling, as well as platforms that facilitate the sale of previously used products (Masnec et al., 2026). Accordingly, clothing sustainability is not limited solely to the way clothing is produced or initially purchased but encompasses consumer behaviour throughout the entire product life cycle, including decisions that extend the useful life of clothing and postpone or prevent its final disposal.

3. RESEARCH FRAMEWORK AND HYPOTHESES

Building on the theoretical background and previous research on clothing consumption and sustainable consumer behaviour, this study focuses on three interrelated areas: *(1) Clothing Purchasing Habits*, *(2) Awareness of the Consequences and Impacts of the Fashion Industry*, and *(3) Sustainable Clothing-Related Behaviour*.

The contemporary fashion market, particularly the expansion of fast fashion business models, has contributed to the widespread availability of clothing, rapidly changing fashion trends, and relatively low prices, potentially encouraging more frequent consumption (Niinimäki et al., 2020; Olivar Aponte et al., 2024). At the same time, the development of digital shopping environments has made clothing increasingly accessible to consumers, while intensive marketing and promotional activities may further stimulate purchasing behaviour (Djafarova & Bowes, 2021; Sundström et al., 2019). These disruptions raise important questions regarding contemporary clothing purchasing patterns and the extent to which consumers' awareness of the broader consequences of fashion consumption is reflected in more sustainable behaviour. Accordingly, the following research questions were formulated:

- RQ1: What are the key characteristics of consumers' clothing purchasing habits?
- RQ2: What is the relationship between consumers' awareness of the consequences and impacts of the fashion industry and their sustainable clothing-related behaviour?

The first research question focuses on consumers' clothing purchasing habits, including how frequently they purchase clothing, the channels through which they make purchases, the criteria they consider when selecting clothing, their expenditure on clothing, and their purchasing behaviour related to fast fashion and second-hand clothing. In this way, RQ1 provides insight into contemporary clothing consumption patterns among the respondents. The second research question focuses on the relationship between consumers' awareness of the consequences and impacts of the fashion industry and their sustainable clothing-related behaviour. Within the proposed research framework, consumer awareness is considered through three dimensions of sustainability (environmental, social, and economic) whereas sustainable clothing-related behaviour is examined across three key stages of clothing consumption (purchasing, use, and disposal) (Soyer & Dittrich, 2021).

The conceptual research model is based on the assumption that a higher level of consumer awareness of the consequences and impacts of fashion consumption is associated with greater engagement in sustainable clothing-related practices. Greater understanding of the environmental, social, and economic consequences of the fashion industry may encourage consumers to make more responsible decisions throughout the clothing consumption process (Soyer & Dittrich, 2021). However, awareness of sustainability-related issues does not necessarily translate into corresponding behaviour, making it particularly relevant to examine

whether higher levels of awareness are associated with more sustainable practices across the purchasing, use, and disposal stages of clothing consumption (Harris et al., 2016; Teerakapibal & Schlegelmilch, 2024; Wiederhold & Martinez, 2018). Based on this reasoning, the following hypothesis was formulated:

H1: Consumers' awareness of the consequences and impacts of the fashion industry is positively associated with sustainable clothing-related behaviour.

Accordingly, the aim of this study is to examine consumers' clothing purchasing habits and investigate the relationship between their awareness of the consequences and impacts of fashion consumption and their sustainable clothing-related practices, as well as to determine the extent to which these constructs are associated among consumers in the Republic of Croatia.

4. METHODOLOGY

To investigate consumers' clothing purchasing habits, their awareness of the consequences and impacts of the fashion industry, and their sustainable practices related to the purchasing, use, and disposal of clothing, an empirical study based on a quantitative research approach was conducted. Primary data were collected using an adapted questionnaire comprising items derived from a previously validated measurement instrument developed by Park and Lee (2021), supplemented by additional questions developed based on relevant scientific literature and aligned with the objectives of the study.

The first research question (RQ1), which focused on consumers' clothing purchasing habits, was addressed using descriptive statistical analysis to provide an overview of respondents' purchasing patterns and behaviours. The second research question (RQ2), which examined the relationship between consumers' awareness of the consequences and impacts of the fashion industry and their sustainable clothing-related behaviour, was addressed using correlation analysis.

The questionnaire consisted of four thematic sections: (1) *General Characteristics of Respondents*, (2) *Clothing Purchasing Habits*, (3) *Awareness of the Consequences and Impacts of the Fashion Industry*, and (4) *Sustainable Clothing-Related Behaviour*. The first section, *General Characteristics of Respondents*, included 10 questions addressing respondents' sociodemographic characteristics, such as gender, age, level of education, employment status, income level, household size, and other relevant characteristics. The second section, *Clothing Purchasing Habits*, comprised seven questions designed to collect data on the frequency of clothing purchases (Kondyli et al., 2026; Weber & Weber, 2022), preferred places of purchase, criteria considered when selecting clothing, the purchase of fast fashion products, the purchase of second-hand clothing (Barrera-Verdugo & Villarroel-Villarroel, 2022; Jeong & Lee, 2014), and other aspects of clothing purchasing behaviour. The first two sections were developed based on relevant scientific literature addressing related research topics. The third section examined *Awareness of the Consequences and Impacts of the Fashion Industry* and consisted of three groups of items corresponding to three dimensions: awareness of environmental consequences (3 items), awareness of social consequences (4 items), and awareness of the economic consequences of the fashion industry (5 items). Items addressing environmental consequences (PEIC in the original study) and social consequences (PSIC in the original study) were adapted from the original questionnaire developed by Park and Lee (2021). Additional items addressing economic consequences were developed to ensure that the assessment of respondents' awareness encompassed all three dimensions of sustainability, environmental, social, and

economic (United Nations Environment Programme, 2017). The fourth section examined *Sustainable Clothing-Related Behaviour* and was divided into three groups of items addressing consumer behaviour across different stages of clothing consumption including purchasing, use, and disposal. The purchasing dimension comprised 26 items representing six sub-constructs identified in the original study (SPB, KSP, MCB, AB, BL, and SVR), while the use dimension comprised 19 items representing three sub-constructs (SUDB, KSUD, and BSC). The disposal dimension consisted of 12 items addressing consumer practices related to the handling of clothing after use. These items were additionally developed for the purposes of this study based on findings from relevant scientific literature on clothing disposal and post-use practices (Joung & Park-Poaps, 2013; Laitala, 2014). Overall, the questionnaire comprised a total of 67 items.

Different types of measurement scales were used depending on the nature of the variables included in the questionnaire. Sociodemographic characteristics were measured using nominal and ordinal scales. Nominal scales were applied to categorical variables without an inherent order, such as gender, employment status, and place of residence, whereas ordinal scales were used for variables with naturally ordered categories, such as age groups, level of education, monthly income, and household size. Data on clothing purchasing habits were collected using ordinal categorical scales and Likert-type scales, depending on the variable being measured. A five-point Likert scale was used to measure the constructs related to respondents' awareness of the consequences and impacts of the fashion industry and their sustainable clothing-related behaviour across the purchasing, use, and disposal stages. Respondents indicated their level of agreement with each statement on the five-point scale. The questionnaire was distributed to respondents via social media channels from mid-July to early September 2026. The questionnaire was shared in three separate distribution cycles to increase its reach and encourage a larger number of respondents to participate in the study. The study employed a non-probability convenience sampling approach, with participants recruited from the Republic of Croatia, predominantly from the northern part of the country.

The internal consistency of the measurement scales was assessed using Cronbach's alpha coefficient (Cronbach, 1951), while corrected item-total correlations (CITC) were examined to assess the consistency of individual items with their respective constructs. Items with low CITC values were further evaluated based on their statistical performance and conceptual relevance, and reliability analysis was repeated following item removal where appropriate. Cronbach's alpha values of .70 or higher were generally considered acceptable, while slightly lower values were interpreted considering the number of items and their CITC values.

To explore the underlying factor structure of the measurement instrument, exploratory factor analysis (EFA) was conducted (Fabrigar et al., 1999; Williams et al., 2010). Given that the questionnaire covered four theoretically distinct domains, *Awareness*, *Sustainable Clothing Purchasing Behaviour*, *Sustainable Clothing Use Behaviour*, and *Sustainable Clothing Disposal Behaviour*, separate EFAs were performed for each domain rather than analysing all items simultaneously. Principal Axis Factoring (PAF) was selected as the extraction method to identify the underlying latent factors based on the shared variance among items. Direct Oblimin rotation with Kaiser Normalization was applied, allowing correlations between the extracted factors, as the dimensions of awareness and sustainable clothing-related behaviour were theoretically expected to be associated. Factor loadings were interpreted using the rotated Pattern Matrix. As an oblique rotation method was applied, pattern coefficients represent regression-based factor coefficients rather than simple item-factor correlations and may occasionally exceed an absolute value of 1.00. Where such coefficients occurred, the corresponding Structure Matrix coefficients, extracted communalities, and convergence

diagnostics were additionally examined. The suitability of the data for factor analysis was assessed using the Kaiser–Meyer–Olkin (KMO) measure of sampling adequacy and Bartlett’s test of sphericity. Item communalities and factor loadings were subsequently examined to evaluate the contribution of individual items to the extracted factor structure. The eigenvalue-greater-than-one criterion was initially used to determine the number of factors, while the theoretical interpretability of the resulting factor solutions was also considered. Factor loadings below 0.30 were suppressed in the displayed pattern matrices. Items exhibiting particularly low communalities, weak factor loadings, or theoretically inconsistent factor allocation were further examined. Decisions regarding item retention or exclusion were based on a combination of statistical indicators and theoretical considerations rather than on a single numerical threshold. Where necessary, EFA was repeated following item exclusion, and alternative factor solutions were examined to assess their interpretability.

Given the sample size ($N = 125$), the adequacy of the data was evaluated separately for each questionnaire domain using KMO statistics, Bartlett’s test of sphericity, extracted communalities, and factor-loading patterns. Nevertheless, these diagnostic indicators do not eliminate the limitations associated with the relatively small sample, particularly for domains containing a larger number of items. Therefore, the resulting factor structures are interpreted as preliminary exploratory evidence rather than definitive confirmation of construct validity. Further validation using a larger independent sample, including respondents from different regions of Croatia, is recommended. Respondents’ sociodemographic characteristics and clothing purchasing habits were analysed using descriptive statistics. The research hypotheses were tested using correlation analysis, with Spearman’s rank correlation coefficient applied to examine the relationships between the investigated variables. To account for the increased risk of Type I errors associated with multiple comparisons, the Holm–Bonferroni correction was applied to the 27 correlation tests examining the relationships between the three awareness dimensions and nine dimensions of sustainable clothing behaviour. Statistical significance was evaluated using Holm-adjusted p-values at an alpha level of 0.05. Data analysis was performed using Microsoft Excel and IBM SPSS Statistics, with EFA, reliability analysis, and Spearman’s correlation analysis conducted in IBM SPSS Statistics.

5. RESEARCH RESULTS

The results are presented in two main parts. First, descriptive statistics are provided to characterize the sample in terms of respondents’ socio-demographic characteristics and their clothing purchasing habits. This is followed by a correlation analysis examining the relationships between consumers’ awareness of the consequences and impacts of the fashion industry and different dimensions of sustainable clothing-related behaviour.

5.1. RESPONDENT CHARACTERISTICS AND CLOTHING PURCHASING HABITS

A total of 125 respondents participated in the study, of whom 92 (73.6%) were female and 33 (26.4%) were male. Almost half of the respondents (48.8%) were aged between 25 and 34 years, followed by those aged 35 – 44 (22.4%) and 18 – 24 (16.0%). In terms of educational attainment, the largest proportion of respondents (45.6%; $n = 57$) had completed a specialist professional graduate study programme or university graduate study programme / integrated undergraduate and graduate university study programme. A further 24.8% ($n = 31$) had completed a four-year secondary school programme, while 16.8% ($n = 21$) had completed a

professional or university undergraduate study programme. Regarding employment status, 81 respondents (64.8%) were permanently employed, while 20 respondents (16%) were employed on fixed-term contracts and another 20 (16%) were students. Most respondents came from Northern Croatia (82.4%; $n = 103$), followed by Zagreb and the surrounding area (11.2%; $n = 14$). The majority of respondents (61.6%; $n = 77$) lived in rural areas, while 38.4% ($n = 48$) lived in urban areas. Regarding household size, 31.2% of respondents lived in four-person households and 27.2% in three-person households, while equal proportions (13.6%) lived in households consisting of either two or five members. In terms of individual monthly net income, 29.6% of respondents reported earning between 1,251 and 1,750 euros, 19.2% between 1,751 and 2,250 euros, and 17.6% between 751 and 1,250 euros. Almost half of the respondents (45.6%) lived in households in which two members earned a monthly income, while 20% lived in households with three income-earning members. Regarding total monthly net household income, the largest proportion of respondents (20%) reported a household income exceeding 5,000 euros, followed by those with a monthly household income between 4,001 and 5,000 euros (17.6%) and those with an income between 3,001 and 4,000 euros (16.8%).

Regarding respondents' clothing purchasing habits, the largest proportion of respondents purchase new clothing several times a year (32.8%), followed by those who purchase clothing every two to three months (25.6%) and once a month (24%). A further 10.4% of respondents purchase clothing several times a month, while 7.2% do so less frequently. In addition, 46.4% of respondents report that they do not purchase clothing on a monthly basis, while 33.6% purchase up to two items per month. Only 17.6% of respondents purchase three to five items, while 2.4% purchase six to ten items of clothing per month. Respondents most frequently purchase clothing from online stores ($M = 3.56$) and shopping centers ($M = 3.41$), while other purchasing channels are considerably less frequently used, including local producers ($M = 1.78$), second-hand stores ($M = 1.65$), and social media ($M = 1.55$). It is worth noting that 65.6% of respondents never purchase clothing from second-hand stores, 46.4% never purchase from local producers, and as many as 66.4% never purchase clothing through social media. These results are presented in Table 1.

Table 1. Frequency of Clothing Purchases by Purchasing Channel

Purchasing Channel	Mean (M)	Standard deviation (SD)
Online stores	3.56	1.16
Shopping centers	3.41	1.01
Local producers	1.78	0.93
Second-hand stores	1.65	1.05
Social media	1.55	0.89

Source: Author(s)

Purchasing from fast fashion retailers is highly prevalent among respondents. As many as 28.8% of respondents report purchasing from fast fashion retailers very often, while an additional 23.2% do so often. Only one respondent (0.8%) reports never purchasing fast fashion clothing. In contrast, second-hand clothing purchases are considerably less common. A total of 61.6% of respondents never purchase second-hand clothing, while an additional 16.8% do so rarely. Only 5.6% of respondents purchase second-hand clothing often or very often. Furthermore, 40% of respondents report that they do not purchase clothing on a monthly basis. Among respondents who report monthly spending on clothing, the most common expenditure category is between 51 and 100 euros (21.6%), followed by 21 to 50 euros (17.6%). A total of

12% of respondents spend between 101 and 200 euros per month on clothing, while 6.4% spend up to 20 euros and only 2.4% spend more than 200 euros per month.

As shown in Table 2, the most important criteria for respondents when purchasing clothing are quality ($M = 4.20$; $SD = 0.81$), design ($M = 4.05$; $SD = 0.97$), durability ($M = 4.03$; $SD = 0.92$), and price ($M = 3.86$; $SD = 0.97$). Brand ($M = 2.26$; $SD = 1.04$) and fashion trends ($M = 2.36$; $SD = 1.10$) are considered relatively less important, while country of production is rated as the least important criterion ($M = 1.95$; $SD = 1.03$). Product sustainability is particularly noteworthy, as its mean value is approximately at the midpoint of the scale ($M = 2.99$; $SD = 1.20$). On average, respondents therefore attach moderate importance to product sustainability, although it is considered less important than more immediate product-related attributes such as quality, design, durability, and price. At the same time, product sustainability has the highest standard deviation among the criteria examined, indicating greater variation among respondents in the importance assigned to this criterion. In other words, while sustainability represents an important clothing purchasing criterion for some respondents, others attach considerably less importance to it.

Table 2. Importance of Criteria When Purchasing Clothing

Criterion	Mean (M)	Standard deviation (SD)
Quality	4.20	0.81
Design	4.05	0.97
Durability	4.03	0.92
Price	3.86	0.97
Product sustainability	2.99	1.20
Fashion trends	2.36	1.10
Brand	2.26	1.04
Country of production	1.95	1.03

Source: Author(s)

5.2. CORRELATION ANALYSIS OF AWARENESS AND SUSTAINABLE CLOTHING BEHAVIOUR

EFA was initially conducted on 12 items measuring awareness of the environmental, social, and economic impacts of the fashion industry. The Kaiser–Meyer–Olkin (KMO) measure indicated good sampling adequacy ($KMO = 0.851$), while Bartlett’s test of sphericity was statistically significant ($\chi^2(66) = 978.400$, $p < 0.001$), supporting the suitability of the correlation matrix for factor analysis. Extracted communalities ranged from 0.346 to 0.901 ($M = 0.661$), with 11 of the 12 items exceeding 0.50. The analysis yielded a three-factor solution based on the eigenvalue-greater-than-one criterion, explaining 66.09% of the total variance after extraction. The rotated pattern matrix revealed a theoretically interpretable structure corresponding to *Economic Awareness* (five items), *Environmental Awareness* (three items), and *Social Awareness* (four items). All primary factor loadings exceeded 0.60, ranging from 0.610 to 0.963, with no displayed cross-loadings of 0.30 or higher. Moderate positive correlations were observed between the extracted factors ($r = 0.342$ – 0.495). All 12 items were retained, providing preliminary empirical support for the proposed three-dimensional structure of awareness.

EFA was subsequently performed on 26 items measuring *Sustainable Clothing Purchasing Behaviour*. The initial results indicated good sampling adequacy ($KMO = 0.895$), while

Bartlett's test of sphericity was statistically significant ($\chi^2(325) = 2549.759$, $p < 0.001$). However, one item (SB_P_SH1_32) exhibited a low communality (0.295) and loaded on a factor different from its theoretically expected dimension (-0.356). Consequently, this item was excluded, and the analysis was repeated using the remaining 25 items. The revised analysis demonstrated good sampling adequacy ($KMO = 0.894$), with a statistically significant Bartlett's test of sphericity ($\chi^2(300) = 2505.604$, $p < 0.001$). Extracted communalities ranged from 0.266 to 0.901, with 24 of the 25 items exhibiting values of at least 0.40. Five factors were extracted based on the eigenvalue-greater-than-one criterion, collectively explaining 65.58% of the total variance after extraction. The rotated pattern matrix revealed a largely interpretable structure corresponding to the five theoretically proposed dimensions of *Sustainable Clothing Purchasing Behaviour*. Primary factor loadings ranged from 0.397 to 0.976 in absolute value. Nevertheless, two items exhibited cross-loadings, while one item showed a comparatively low communality (0.266), despite loading on its theoretically expected factor (0.416). Overall, the results provide preliminary empirical support for the proposed five-dimensional structure. However, considering the relatively limited sample size, the presence of a two-item factor, and several item-level limitations, further validation using a larger independent sample is recommended.

EFA was subsequently conducted on 18 items measuring *Sustainable Clothing Use Behaviour*. The KMO measure indicated good sampling adequacy ($KMO = 0.826$), while Bartlett's test of sphericity was statistically significant ($\chi^2(153) = 1188.450$, $p < 0.001$), supporting the suitability of the correlation matrix for factor analysis. Extracted communalities ranged from 0.240 to 0.953, with 16 of the 18 items exhibiting values of at least 0.40. Based on the eigenvalue-greater-than-one criterion, four factors were extracted, collectively explaining 56.51% of the total variance after extraction. The rotated Pattern Matrix revealed an exploratory four-factor solution, with primary factor loadings ranging from 0.375 to 0.949 in absolute value. The items were generally distributed across the extracted factors in a manner consistent with their conceptual content. Nevertheless, several items exhibited cross-loadings, while one item showed a comparatively low communality (0.240). These items were retained considering their theoretical relevance and primary factor loadings. Although the exploratory analysis identified four factors, the two theoretically predefined composite dimensions of *Sustainable Clothing Use Behaviour* were retained for the subsequent reliability and correlation analyses. This decision was based on the conceptual structure of the measurement instrument and the preliminary nature of the exploratory solution. The discrepancy between the exploratory factor structure and the theoretically defined dimensions is acknowledged as a limitation requiring further investigation and validation using a larger independent sample.

Finally, EFA was conducted on 11 items measuring *Sustainable Clothing Disposal Behaviour*. The initial analysis indicated acceptable sampling adequacy ($KMO = 0.762$), while Bartlett's test of sphericity was statistically significant ($\chi^2(55) = 401.276$, $p < 0.001$). The initial four-factor solution explained 50.91% of the total variance after extraction. However, the resulting structure included a single-item factor and several items with comparatively low communalities. Considering the theoretically proposed two-dimensional structure, an alternative two-factor solution was examined. Two items demonstrated particularly low communalities (0.099 and 0.204, respectively) and no displayed factor loadings of 0.30 or higher. Consequently, these items were excluded, and EFA was repeated using the remaining nine items, with the extraction restricted to two factors. The revised analysis demonstrated acceptable sampling adequacy ($KMO = 0.758$), with a statistically significant Bartlett's test of sphericity ($\chi^2(36) = 335.187$, $p < 0.001$). The two-factor solution explained 45.48% of the total variance after extraction, with extracted communalities ranging from 0.165 to 0.950. The

rotated Pattern Matrix revealed a theoretically interpretable structure, with six items loading on the first factor (0.427–0.817) and three items loading on the second factor (0.438–1.036), consistent with the two proposed dimensions. No cross-loadings of 0.30 or higher were observed in the Pattern Matrix. One item exhibited a pattern coefficient slightly exceeding 1.00 (1.036). As Direct Oblimin rotation was applied, the reported pattern coefficients represent oblique regression coefficients rather than simple item–factor correlations. Additional diagnostic examination revealed a corresponding structure coefficient of 0.960 and an extracted communality of 0.950, while the correlation between the two factors was 0.411. The extraction converged after 41 iterations. Although the revised solution showed a theoretically interpretable two-factor structure, several items retained relatively low communalities (0.165–0.328). Therefore, the findings should be interpreted as preliminary support for the proposed two-dimensional structure rather than definitive evidence of construct validity. Further validation using a larger independent sample is recommended.

Table 3. Internal Consistency and Item Analysis of the Measurement Scales

Construct	Final (Initial) No. of Items	CITC Range	Cronbach's α
Environmental Awareness	3 (3)	.813 - .898	.929
Social Awareness	4 (4)	.503 - .670	.790
Economic Awareness	5 (5)	.699 - .799	.904
Clothing Purchasing Practices	11 (11)	.534 - .842	.939
Sustainable Clothing Purchasing Knowledge	3 (3)	.739 - .856	.907
Activist Behaviour	5 (5)	.761 - .888	.932
Reduced Purchasing Behaviour	4 (4)	.425 - .499	.676
Second-Hand, Vintage, and Clothing Rental	2 (3)	.789 - .789	.882
Sustainable Clothing Use and Storage Practices and Knowledge	13 (13)	.400 - .774	.884
Sustainable Clothing Consumption Beliefs	5 (5)	.562 - .739	.845
Clothing Donation and Return	3 (5)	.407 - .621	.671
Alteration and Repurposing Practices	6 (6)	.363 - .690	.793

Source: Author(s)

As presented in Table 3, most measurement scales demonstrated acceptable to high internal consistency, with Cronbach's alpha coefficients ranging from 0.790 to 0.939. Two dimensions, *Reduced Purchasing Behaviour* ($\alpha = 0.676$) and *Clothing Donation and Return* ($\alpha = 0.671$), exhibited slightly lower reliability estimates. These values were interpreted cautiously, considering the relatively small number of items and their corrected item–total correlations. The corresponding dimensions were retained based on their theoretical relevance, although their reliability should be further examined in future studies.

Table 4 presents the results of Spearman's correlation analysis examining the relationships between the three dimensions of awareness of the consequences of fashion consumption and nine dimensions of sustainable clothing behaviour. Statistical significance was evaluated using the Holm–Bonferroni correction to account for multiple comparisons.

Table 4. Spearman's Correlation Analysis of Awareness and Sustainable Clothing Behaviour

Sustainable Behaviour		Awareness of the Consequences and Impacts of the Fashion Industry		
		Environmental	Social	Economic
Clothing Purchasing	Clothing Purchasing Practices	.231	.301*	.189
	Sustainable Clothing Purchasing Knowledge	.312*	.299*	.111
	Activist Behaviour	.135	.191	.042
	Reduced Purchasing Behaviour	.395*	.295*	.441*
	Second-Hand, Vintage, and Clothing Rental	.143	.150	-.079
Clothing Use	Sustainable Clothing Use and Storage Practices and Knowledge	.411*	.438*	.345*
	Sustainable Clothing Consumption Beliefs	.201	.201	.392*
Clothing Disposal	Clothing Donation and Return	.147	.149	.245
	Alteration and Repurposing Practices	.211	.231	.252
Note: Values represent Spearman's rank correlation coefficients (ρ). N = 125. * indicates statistical significance at Holm-adjusted $p < .05$ (two-tailed), accounting for 27 comparisons.				

Source: Author(s)

Table 4 presents the results of Spearman's correlation analysis examining the relationships between environmental, social, and economic awareness of the consequences of fashion consumption and nine dimensions of sustainable clothing behaviour. To account for multiple comparisons, the Holm–Bonferroni correction was applied to all 27 correlation tests. Following the correction, ten positive associations remained statistically significant (adjusted $p < .05$). Environmental awareness showed significant positive associations with *Sustainable Clothing Purchasing Knowledge* ($\rho = 0.312$), *Reduced Purchasing Behaviour* ($\rho = 0.395$), and *Sustainable Clothing Use and Storage Practices and Knowledge* ($\rho = 0.411$). Social awareness was significantly associated with *Clothing Purchasing Practices* ($\rho = 0.301$), *Sustainable Clothing Purchasing Knowledge* ($\rho = 0.299$), *Reduced Purchasing Behaviour* ($\rho = 0.295$), and *Sustainable Clothing Use and Storage Practices and Knowledge* ($\rho = 0.438$). Economic awareness demonstrated significant positive associations with *Reduced Purchasing Behaviour* ($\rho = 0.441$), *Sustainable Clothing Use and Storage Practices and Knowledge* ($\rho = 0.345$), and *Sustainable Clothing Consumption Beliefs* ($\rho = 0.392$). No associations involving *Activist Behaviour*, *Second-Hand, Vintage, and Clothing Rental*, *Clothing Donation and Return*, or *Alteration and Repurposing Practices* remained statistically significant after the correction. Overall, the statistically significant correlations ranged from 0.295 to 0.441, indicating weak-to-moderate positive associations between awareness and selected dimensions of sustainable clothing behaviour. These findings suggest that awareness is related to certain sustainable practices, particularly reduced purchasing behaviour and sustainable clothing use and storage. However, the magnitude of these associations should be interpreted cautiously and does not establish a causal relationship between awareness and sustainable clothing consumption.

6. DISCUSSION

The aim of this study was to examine the structure of consumer awareness regarding the impacts of the fashion industry and to analyse its relationship with various dimensions of sustainable clothing-related behaviour. The findings related to RQ1 indicate that respondents' clothing purchasing habits are characterised by relatively moderate purchasing frequency and expenditure, a clear preference for online stores and shopping centres as purchasing channels, and a high prevalence of fast fashion purchasing compared with second-hand clothing. When selecting clothing, respondents primarily prioritise quality, design, durability, and price, while product sustainability plays a secondary role and varies considerably in importance across respondents. Regarding RQ2, the findings revealed statistically significant positive associations between awareness and selected dimensions of sustainable clothing behaviour. Following the Holm–Bonferroni correction for multiple comparisons, ten of the 27 examined correlations remained statistically significant. In particular, *Reduced Purchasing Behaviour* demonstrated consistent positive associations with all three dimensions of awareness ($p = 0.295–0.441$). This dimension includes practices aimed at reducing clothing purchases in general, minimising impulse buying, and avoiding the purchase of clothing items similar to those already owned.

Similarly, *Sustainable Clothing Use and Storage Practices and Knowledge* was positively associated with environmental, social, and economic awareness ($p = 0.345–0.438$). This dimension encompasses practical behaviours, such as proper clothing care and storage, combining different clothing items, and organising existing clothing, as well as knowledge related to clothing care labels, garment repair, recycling programmes, and clothing use and styling. These findings suggest that higher levels of awareness tend to be associated with selected practices related to reducing clothing consumption and extending the use of existing garments.

Other statistically significant associations were identified between social awareness and *Clothing Purchasing Practices* ($p = 0.301$), environmental and social awareness and *Sustainable Clothing Purchasing Knowledge* ($p = 0.312$ and 0.299 , respectively), and economic awareness and *Sustainable Clothing Consumption Beliefs* ($p = 0.392$). However, no statistically significant associations involving *Activist Behaviour*, *Second-Hand*, *Vintage*, and *Clothing Rental*, *Clothing Donation and Return*, or *Alteration and Repurposing Practices* remained after the correction.

Overall, the findings provide partial support for H1, indicating that awareness of the environmental, social, and economic consequences of fashion consumption is positively associated with certain dimensions of sustainable clothing behaviour, rather than with sustainable clothing practices in general. The statistically significant correlations were weak to moderate in magnitude ($p = 0.295–0.441$), suggesting that awareness alone should not be considered a strong indicator of sustainable clothing consumption. Furthermore, given the cross-sectional and correlational nature of the study, these relationships should not be interpreted as causal.

The results of this study partially align with the findings of Park & Lee, (2021), whose measurement instrument served as the basis for the questionnaire, while also revealing certain differences. Whereas Park and Lee identified five dimensions of awareness and six dimensions of sustainable behaviour, this study identified three dimensions of awareness (environmental, social, and economic), while sustainable clothing behaviour was examined across the stages of purchasing, use, and disposal. The observed associations suggest that awareness is related to

selected sustainable practices, particularly reduced purchasing behaviour and sustainable clothing use and storage. However, unlike the findings reported by Park & Lee, (2021), no statistically significant association between awareness and second-hand or vintage clothing purchasing or clothing rental was identified in the present study.

This finding can be discussed in relation to previous research by Soyer and Dittrich (2021) and Teerakapibal and Schlegelmilch (2024), which highlights the potential gap between positive attitudes towards sustainability and actual consumer behaviour. The absence of statistically significant associations for several behavioural dimensions suggests that awareness may not be equally related to all forms of sustainable clothing consumption. Nevertheless, these findings should be interpreted cautiously, as non-significant correlations do not necessarily indicate the absence of a relationship, particularly given the relatively small sample size and the correction applied for multiple comparisons.

7. CONCLUSION

The growing imbalance between increasing clothing production and the decreasing period of clothing use represents an important sustainability challenge that requires changes not only within the fashion industry but also in consumer behaviour. Although sustainable consumption initiatives are becoming increasingly visible, the findings of this study indicate that conventional consumption patterns remain strongly present among respondents included in this study. Fast fashion purchasing is widespread, second-hand clothing remains relatively uncommon, and sustainability plays a secondary role compared with quality, design, durability, and price when purchasing clothing.

At the same time, greater awareness of the environmental, social, and economic consequences of the fashion industry was associated with selected dimensions of sustainable clothing-related behaviour, particularly reduced purchasing and sustainable clothing use and storage. However, awareness was not equally associated with all forms of sustainable behaviour. This suggests that informing consumers and raising sustainability awareness alone may not be sufficient to substantially change clothing consumption patterns. Sustainable alternatives should therefore also become more accessible, economically viable, and attractive to consumers. In this context, the further development of digital platforms for clothing exchange and rental, together with initiatives aimed at increasing the acceptance of second-hand clothing through contemporary marketing approaches, may contribute to making circular clothing practices more accessible and appealing to consumers.

Several limitations should be considered when interpreting the findings. The study was based on a relatively small convenience sample of 125 respondents, with an overrepresentation of women, younger adults, and participants from Northern Croatia, which limits the generalizability of the findings to the broader Croatian population. Furthermore, the study relied on self-reported behaviour, which may not fully reflect consumers' actual clothing-related practices. Future research should therefore include larger, more diverse, and more representative samples and further examine the factors that facilitate or hinder the translation of sustainability awareness into actual consumer behaviour.

ACKNOWLEDGEMENT

This research has been conducted as part of the wider research in the project Value Perspectives in Digital Transformation Initiatives (VPiDT), which is funded by European Union - NextGenerationEU.

REFERENCES

1. Alalwan, A. A., Rana, N. P., Dwivedi, Y. K., & Algharabat, R. (2017). Social media in marketing: A review and analysis of the existing literature. *Telematics and Informatics*, 34(7), 1177–1190. <https://doi.org/10.1016/j.tele.2017.05.008>
2. Aydin, I., & Takva, E. (2026). Investigation of the moderating role of word of mouth communication on the effect of trust in social media influencer on purchase intention. *Dicle Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 16(31), 429–445.
3. Barreda, A. A., Bilgihan, A., Nusair, K., & Okumus, F. (2015). Generating brand awareness in Online Social Networks. *Computers in Human Behavior*, 50, 600–609. <https://doi.org/10.1016/j.chb.2015.03.023>
4. Barrera-Verdugo, G., & Villarroel-Villarroel, A. (2022). Influence of product selection criteria on clothing purchase and post-purchase behaviours: A gender and generational comparison. *PLOS ONE*, 17(6), e0267783. <https://doi.org/10.1371/journal.pone.0267783>
5. Butler, S. (2026, April 2). Secondhand clothes sales forecast to hit \$289bn as AI helps shoppers find deals. *The Guardian*. <https://www.theguardian.com/business/2026/apr/02/secondhand-clothes-sales-forecast-to-hit-289bn-as-ai-helps-shoppers-find-deals>
6. Büyükdağ, N. (2021). The effect of brand awareness, brand image, satisfaction, brand loyalty and WOM on purchase intention: An empirical research on social media. *Business & Management Studies: An International Journal*, 9(4), 1380–1398. <https://doi.org/10.15295/bmij.v9i4.1902>
7. Cavender, R. C., & Lee, M.-Y. (2018). Exploring the Influence of Sustainability Knowledge and Orientation to Slow Consumption on Fashion Leaders' Drivers of Fast Fashion Avoidance. *American Journal of Theoretical and Applied Business*, 4(3), 90. <https://doi.org/10.11648/j.ajtab.20180403.12>
8. Cervellon, M., Carey, L., & Harms, T. (2012). Something old, something used: Determinants of women's purchase of vintage fashion vs second-hand fashion. *International Journal of Retail & Distribution Management*, 40(12), 956–974. <https://doi.org/10.1108/09590551211274946>
9. Chan, T. J., Jahid, A. Md., Kamar, N. S., Silvianita, A., Ng, M. L., & Huam, H. T. (2025). Green Social Media Influencers' Characteristics Affect Sustainable Clothing Purchase Intentions Among Millennials: An Extended Source Credibility Framework. *Studies in Media and Communication*, 13(3), 299–309. <https://doi.org/10.11114/smc.v13i3.7640>
10. Chanillo, R. S. (2026). Consumer Purchase Behaviour Toward Handmade Lifestyle Products on Social Media: A Case Study of Instagram Marketing. *International Research Journal of Education and Technology*, 9(4), 446–457.
11. Cronbach, L. J. (1951). Coefficient alpha and the internal structure of tests. *Psychometrika*, 16(3), 297–334. <https://doi.org/10.1007/BF02310555>
12. Dehyadegari, S., Nekuie, F., Poursaeed, M. M., & Pourjoupari, Z. (2025). Investigating the role of social media influencers on the online buying behavior of hijab clothing by women in Iran. *Journal of Islamic Marketing*, 16(11), 3154–3172. <https://doi.org/10.1108/JIMA-10-2024-0489>

13. 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. <https://doi.org/10.1016/j.jretconser.2020.102345>
14. Domingos, M., Vale, V. T., & Faria, S. (2022). Slow Fashion Consumer Behavior: A Literature Review. *Sustainability*, 14(5), 2860. <https://doi.org/10.3390/su14052860>
15. Eisinga, R., Grotenhuis, M. te, & Pelzer, B. (2013). The reliability of a two-item scale: Pearson, Cronbach, or Spearman-Brown? *International Journal of Public Health*, 58(4), 637–642. <https://doi.org/10.1007/s00038-012-0416-3>
16. Fabrigar, L., Wegener, D., MacCallum, R., & Strahan, E. (1999). Evaluating the use of Exploratory Factor Analysis in psychological research. *Psychological Methods*, 4, 272–299. <https://doi.org/10.1037//1082-989X.4.3.272>
17. Hajli, N. (2015). Social commerce constructs and consumer's intention to buy. *International Journal of Information Management*, 35(2), 183–191. <https://doi.org/10.1016/j.ijinfomgt.2014.12.005>
18. Harris, F., Roby, H., & Dibb, S. (2016). Sustainable clothing: Challenges, barriers and interventions for encouraging more sustainable consumer behaviour. *International Journal of Consumer Studies*, 40(3), 309–318. <https://doi.org/10.1111/ijcs.12257>
19. He, X., & Hu, Y. (2026). When sustainability meets risk perception: An extended goal-directed behavior model of consumers' sustainable clothing purchase intentions. *Journal of Fashion Marketing and Management: An International Journal*, 1–20. <https://doi.org/10.1108/JFMM-06-2025-0275>
20. Hsu, S.-C., Liao, Y.-K., Huang, K.-C., Lin, L.-C., Thinh, V. T., Wu, W.-Y., & Sharma, K. (2026). Psychological Drivers and Behavioral Outcomes of Fast Fashion Consumption: A Meta-Analytic. *F1000Research*, 14(1256), 1–33.
21. International Labour Organization. (n.d.). *How to achieve gender equality in global garment supply chains*. Retrieved September 4, 2026, from <https://webapps.ilo.org/infostories/en-GB/Stories/discrimination/garment-gender.html#introduction>
22. International Labour Organization. (2025, March 28). *Decent Work Challenges and Opportunities in the Textiles and Clothing Sector*. <https://www.ilo.org/publications/decent-work-challenges-and-opportunities-textiles-and-clothing-sector>
23. Jeong, S. W., & Lee, K.-H. (2014). Impact of evaluative criteria on satisfaction and dissatisfaction: Identifying the role of knitwear involvement. *Fashion and Textiles*, 1(1), 9. <https://doi.org/10.1186/s40691-014-0009-2>
24. Joung, H., & Park-Poaps, H. (2013). Factors motivating and influencing clothing disposal behaviors. *International Journal of Consumer Studies*, 37. <https://doi.org/10.1111/j.1470-6431.2011.01048.x>
25. Kelleher, D. (2026, September 1). *Fast fashion* [Online post]. <https://www.britannica.com/art/fast-fashion>
26. Kondyli, S., Bouliota, S., & Komilis, D. (2026). Clothing Purchase Preferences and Textile Waste Management Practices in Greece: A Practice Theory-Based Study. *Sustainability*, 18(3), 1610. <https://doi.org/10.3390/su18031610>
27. Kuupole, E., Wemegah, R., Awinkeligo, M. H., Adjei, D. A., Armah, L., & Agale, A. S. (2025). EXPLORING FACTORS THAT INFLUENCE CONSUMERS' BEHAVIOUR TOWARD SECOND-HAND CLOTHING PURCHASE. *African Journal of Applied Research*, 11(2), 419–435. <https://doi.org/10.26437/ajar.v11i2.1043>
28. Laitala, K. (2014). Consumers' clothing disposal behaviour – a synthesis of research results. *International Journal of Consumer Studies*, 38(5), 444–457. <https://doi.org/10.1111/ijcs.12088>

29. le Roux, N., du Preez, M., Dreyer, H., & Esterhuizen, N. (2026). Beyond employment status: Consistency in women's clothing purchase decision-making. *Psychological Applications and Trends* 2026, 506–510. <https://doi.org/10.36315/2026inpact114>
30. Londoño-Bedoya, D. A., Lechuga-Cardozo, J. I., Areiza-Padilla, J. A., Veas-González, I., Pardo-Jaramillo, S., & Barajas-Portas, K. (2025). Trust in influencers increases sustainable fashion adoption in emerging markets. *Discover Sustainability*, 6(1), 1289. <https://doi.org/10.1007/s43621-025-01816-3>
31. Machado, M. A. D., Almeida, S. O. D., Bollick, L. C., & Bragagnolo, G. (2019). Second-hand fashion market: Consumer role in circular economy. *Journal of Fashion Marketing and Management: An International Journal*, 23(3), 382–395. <https://doi.org/10.1108/JFMM-07-2018-0099>
32. Makuku, K. K., & Suwitho, S. (2026). The Influence of Impulsivity, Promotional Exposure, and Product Variety on Impulsive Clothing Purchase Decisions Through Positive Emotions (A Case Study of Female Students at Stiesia). *Indonesian Interdisciplinary Journal of Sharia Economics (IIJSE)*, 9(2), 16440–16457.
33. Masnec, L., Hrustek, L., & Kutnjak, A. (2026). The role of sustainable marketing in the transformation of the textile industry towards a circular economy. *CroDiM*, 9(1), 73–83.
34. Niinimäki, K., Peters, G., Dahlbo, H., Perry, P., Rissanen, T., & Gwilt, A. (2020). The environmental price of fast fashion. *Nature Reviews Earth & Environment*, 1(4), 189–200. <https://doi.org/10.1038/s43017-020-0039-9>
35. Nkominopondo, P., Mbukanma, I., & Shemfe, O. (2025). Impact of Social Media Marketing on Consumer Purchasing Decisions for Clothing Products in Mthatha. *Acta Universitatis Danubius. Œconomica.*, 21(5), 231–242.
36. Olivar Aponte, N., Hernández Gómez, J., Torres Argüelles, V., & Smith, E. D. (2024). Fast fashion consumption and its environmental impact: A literature review. *Sustainability: Science, Practice and Policy*, 20(1), 2381871. <https://doi.org/10.1080/15487733.2024.2381871>
37. Park, S., & Lee, Y. (2021). Scale Development of Sustainable Consumption of Clothing Products. *Sustainability*, 13(1), 115. <https://doi.org/10.3390/su13010115>
38. Persson, N. (2010). An exploratory investigation of the elements of B2B brand image and its relationship to price premium. *Industrial Marketing Management*, 39(8), 1269–1277. <https://doi.org/10.1016/j.indmarman.2010.02.024>
39. Putra, F. E., Romadhani, B., & Nurinaya, N. (2026). Brand Image and Fashion Lifestyle Effects on Students' Branded used Clothing Purchase Decisions. *Journal Social Society*, 6(3), 1887–1907. <https://doi.org/https://doi.org/10.54065/jss.6.3.2026.1341>
40. Shamsuzzaman, M., Islam, M., Mamun, Md. A. Al., Rayyaan, R., Sowrov, K., Islam, S., & Sayem, A. S. M. (2025). Fashion and textile waste management in the circular economy: A systematic review. *Cleaner Waste Systems*, 11, 100268. <https://doi.org/10.1016/j.clwas.2025.100268>
41. Silva, S. C., Santos, A., Duarte, P., & Vlačić, B. (2021). *International Journal of Retail and Distribution Management*, 49(6), 717–734. <https://doi.org/10.1108/IJRDM-09-2020-0356>
42. Sinh, N. H. (2026). Drivers and barriers influencing second hand clothing purchase intention within an integrated behavioral framework. *Discover Sustainability*. <https://doi.org/10.1007/s43621-026-03932-0>
43. Song, H., Wang, J., & Han, H. (2019). Effect of image, satisfaction, trust, love, and respect on loyalty formation for name-brand coffee shops. *International Journal of Hospitality Management*, 79, 50–59. <https://doi.org/10.1016/j.ijhm.2018.12.011>

44. Soyer, M., & Dittrich, K. (2021). Sustainable Consumer Behavior in Purchasing, Using and Disposing of Clothes. *Sustainability*, 13(15), 8333. <https://doi.org/10.3390/su13158333>
45. Sundström, M., Hjelm-Lidholm, S., & Radon, A. (2019). Clicking the boredom away – Exploring impulse fashion buying behavior online. *Journal of Retailing and Consumer Services*, 47, 150–156. <https://doi.org/10.1016/j.jretconser.2018.11.006>
46. Teerakapibal, S., & Schlegelmilch, B. B. (2024). Mind the gap: Identifying the chasm between environmental awareness, attitudes and action in fast fashion consumption. *International Marketing Review*, 42(1), 103–127. <https://doi.org/10.1108/IMR-05-2024-0151>
47. Tportal. (2026). *Preloved Market ponovno stiže na Špancirfest*. Tportal.Hr. <https://www.tportal.hr/lifestyle/clanak/preloved-market-ponovno-stize-na-spancirfest-20260821>
48. Tumangger, E. M. K., & Munthe, S. (2025). The Influence of TikTok's For You Page And Lifestyle on Impulsive Buying Decisions of Clothing Products Among Generation Z (Digital Business Students at Universitas Negeri Medan 2021–2022). *Economic: Journal Economic and Business*, 4(4), 643–649.
49. UNEP. (2025, February 7). *Sustainable fashion to take centre stage on Zero Waste Day*. <https://www.unep.org/technical-highlight/sustainable-fashion-take-centre-stage-zero-waste-day>
50. United Nations, Department of Economic and Social Affairs. (n.d.-a). *Goal 5 | Department of Economic and Social Affairs*. Retrieved September 4, 2026, from <https://sdgs.un.org/goals/goal5>
51. United Nations, Department of Economic and Social Affairs. (n.d.-b). *Goal 6 | Department of Economic and Social Affairs*. Retrieved September 4, 2026, from <https://sdgs.un.org/goals/goal6>
52. United Nations, Department of Economic and Social Affairs. (n.d.-c). *Goal 8 | Department of Economic and Social Affairs*. Retrieved September 4, 2026, from <https://sdgs.un.org/goals/goal8>
53. United Nations, Department of Economic and Social Affairs. (n.d.-d). *Goal 12 | Department of Economic and Social Affairs*. Retrieved September 4, 2026, from <https://sdgs.un.org/goals/goal12>
54. United Nations, Department of Economic and Social Affairs. (n.d.-e). *Goal 13 | Department of Economic and Social Affairs*. Retrieved September 4, 2026, from <https://sdgs.un.org/goals/goal13>
55. United Nations, Department of Economic and Social Affairs. (n.d.-f). *Goal 14 | Department of Economic and Social Affairs*. Retrieved September 4, 2026, from <https://sdgs.un.org/goals/goal14>
56. United Nations, Department of Economic and Social Affairs. (n.d.-g). *Goal 15 | Department of Economic and Social Affairs*. Retrieved September 4, 2026, from <https://sdgs.un.org/goals/goal15>
57. United Nations Environment Programme. (2017, September 28). *Environmental, social and sustainability framework | UNEP - UN Environment Programme*. <https://www.unep.org/about-un-environment/why-does-un-environment-matter/environmental-social-and-economic>
58. United Nations Environment Programme. (2025, March 27). *Unsustainable fashion and textiles in focus for International Day of Zero Waste 2025*. <https://www.unep.org/news-and-stories/press-release/unsustainable-fashion-and-textiles-focus-international-day-zero>

59. Weber, S., & Weber, O. (2022). How Fashionable Are We? Validating the Fashion Interest Scale through Multivariate Statistics. *Sustainability*, 14(4), 1946. <https://doi.org/10.3390/su14041946>
60. Wiederhold, M., & Martinez, L. F. (2018). Ethical consumer behaviour in Germany: The attitude-behaviour gap in the green apparel industry. *International Journal of Consumer Studies*, 42(4), 419–429. <https://doi.org/10.1111/ijcs.12435>
61. Williams, B., Onsman, A., & Brown, T. (2010). Exploratory Factor Analysis: A Five-Step Guide for Novices. *Australasian Journal of Paramedicine*, 8, 1–13. <https://doi.org/10.33151/ajp.8.3.93>
62. Zhang, Y., & Caverlee, J. (2019). Instagrammers, fashionistas, and me: Recurrent fashion recommendation with implicit visual influence. *Int Conf Inf Knowledge Manage*, 1583–1592. <https://doi.org/10.1145/3357384.3358042>

Preliminary communication / Prethodno priopćenje

DIGITAL AGE DECEPTION: THE ROLE OF AI IN DISINFORMATION DETECTION

LUKA VIDAČ

University of Zagreb
Faculty of Organization and Informatics
Pavlinka 2, 42000 Varaždin, Croatia
lvidak23@student.foi.hr

RENATA MEKOVEC

University of Zagreb
Faculty of Organization and Informatics
Pavlinka 2, 42000 Varaždin, Croatia
renata.mekovec@foi.hr

ABSTRACT

Rapid advances in technology have changed global communication, but they also contribute to the spread of misinformation, disinformation, and AI-generated content. Global surveys reveal public concern, with digital deception identified as a major danger to democracy, social trust, and online security. While AI technologies make it easy to create fake stories and deepfakes at a minimal cost, they also provide effective disinformation detection tools. This study investigates research trends in disinformation and looks at how AI can be used to address misleading content. The study assesses the efficacy of three AI-powered tools for detecting and reducing digital disinformation.

KEYWORDS: disinformation, misinformation, fact-checking, AI tools

1. INTRODUCTION

Rapid technological revolutions in recent decades have drastically altered how individuals interact, communicate, and access information. People now have access to the entirety of human knowledge on their mobile phones, opening up new opportunities for education, information, and organization. However, these major transformations have negative impacts that we are only now beginning to understand, such as the far faster spread of misinformation, disinformation, and hate speech. With the expanding amount of information available via the internet and social media, there is also an increase in false, manipulative, and misleading content, posing a serious challenge to society. According to a Spring 2025 Pew Research Center (2025) conducted across 25 nations, 72% of adults believe that spreading false information online poses a significant threat to their country. Another 21% consider it a minor threat, while 5% believe it is not a problem at all. In seven nations (Germany, the Netherlands, Poland, Sweden, the United Kingdom, the United States, and South Korea), the dissemination of misinformation is perceived as the most serious concern. False information on the internet is a serious concern in both high- and middle-income countries. The World Economic Forum Global Risks Report

(2024) ranks AI-driven disinformation and misinformation as the top short-term global risk, surpassing extreme weather events, cyberattacks, and geopolitical conflicts, predicting that AI-generated disinformation might jeopardize elections over the next two years.

Statista (2026) reports that the global public is increasingly concerned about the impact of AI on information, elections, and internet safety. According to a global survey conducted in 2025, 64 % of participants expressed concern that AI-generated content could influence elections, while 70 % acknowledged struggling to trust online information since they couldn't identify whether it was created by AI. In the United States, 60% of individuals expressed concern about the spread of deepfake videos and sounds created by AI. Similarly, a 2024 survey in the United Kingdom found that 77 % of girls and young women had suffered online harm in the previous year, with 59 % of respondents being concerned that AI may be used to produce false photos of them or impersonate them online.

The role of AI in this setting is quite unexpected. On the one hand, the same innovations in technology that enable the widespread, low-cost creation of disinformation also provide the most promising set of instruments for detecting and fighting it. Machine learning algorithms, natural language processing (NLP) models, and large language models (LLMs) such as ChatGPT and Claude are currently leading academic and corporate research into the automated identification of manipulative material, misleading claims, and visual forgeries.

The aim of this paper is to investigate current trends in research related to misinformation/disinformation, as well as to analyze the role of AI in detecting disinformation. This paper addresses two research questions:

R1: What is the current trend and level of scholarly attention regarding misinformation/disinformation?

R2: In what ways can artificial intelligence tools be deployed to identify and detect misinformation/disinformation?

2. THE CONTEXT OF DISINFORMATION

The manner in which we obtain knowledge today has evolved considerably from previous times. Conventional media—like television, radio, and printed newspapers—are progressively evolving to digital platforms and social networks that facilitate the swift and effortless distribution of information. As a result, in addition to the numerous benefits of this mode of information consumption, there are also disadvantages that facilitate the dissemination of disinformation and false news. The European Commission (European Court of Auditors 2020) defines disinformation as „the creation, presentation and dissemination of verifiably false or misleading information for the purposes of economic gain or intentionally deceiving the public, and which may cause public harm. Such harm may include undermining democratic processes or threats to public goods“.


Misinformation frequently relies on trends in information generation and delivery technology (Adams et al., 2023). The digital ecosystem is best at spreading misinformation quickly and widely, turning users into information and misinformation producers. On the other hand, an overwhelming amount of knowledge stimulates online sharing and biases information selection, which may have negative effects. A systematic review of the literature presented by Pérez-Escolar, Lilleker, and Tapia-Frade (2023) indicates that disinformation and misinformation are a serious social problem that continues to be studied globally and is of growing concern.

One of the main drivers of the increasing amount of fake news is the way social media platforms operate. Platforms like Facebook, X, and Instagram use algorithms to prioritize content that encourages more user involvement. Fake news spreads more quickly on social media than other types of content (Olan et al., 2022) where personal attributes such as strong extraversion and low conscientiousness, as well as motivations such as information-seeking, social utility, fear of missing out, and emotional regulation, are important contributors in the spread of false news (Yu et al., 2026). A further problem is that users frequently lack the critical thinking and media literacy skills required to recognize untrustworthy sources. According to Orhan (2023), the capacity to recognize fake news is related to an individual's digital literacy and critical thinking skills. In addition, proactive behavior through sharing intention for verified information is influenced by perceived understanding (by attitudes toward information verification) and media literacy (Le, 2026).

Online social networks are constantly expanding, providing infinite easy communication as well as instant news and information (Aïmeur et al., 2023). However, the unchecked spread of false information remains one of their most urgent challenges. Fake news detection on social networks has distinct characteristics and obstacles, making developing a solution anything but simple. To make matters worse, AI techniques such as machine learning and deep learning are being used to fool people by developing and sharing false information.

To evaluate the importance of this topic in scientific research we preformed bibliometric analysis using Scopus database. The literature search was conducted on June 25, 2026. In first step, we define search keywords in title, abstract or keyword list: disinformation OR misinformation OR fake news and no time limit. Results were 18168 publications. When we investigate the number of documents per year it was evident that this topic became actual since 2017 where the number of publications started to grow. Therefore, in the subsequent step, we applied refined exclusion criteria: the timeframe was limited to 2016–2026, which narrowed the total sample to 17,968 documents. In this investigation we were not interested in the language or the document type since.


Figure 1: Documents per year by source



The most common source of publication was Lecture Notes in Computer Science Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics, Lecture Notes in Networks and Systems, CWEUR Workshop Proceedings, Communications in Computer and Information Science, and IEEE Access (Figure 1). Most publication belonged to computer science, social science and engineering (Figure 2).

Figure 2: Documents per subject area

Documents by subject area



The bibliometric analysis indicates an explosion of scientific interest in disinformation, misinformation, and fake news following 2016. The fact that the 2016–2026 timeframe accounts for 98.9% of all identified publications (17,968 out of 18,168) confirms that this is a highly contemporary research challenge. The structure of publication sources and subject areas reveals the core nature of this research landscape where the dominance of Computer Science but also interdisciplinary character is evident. Leading publication venues (such as Lecture Notes in Computer Science, CEUR Workshop Proceedings, and IEEE Access) alongside top subject area distributions demonstrate that misinformation/disinformation is predominantly approached through a technical and technological lens. The presence of Social Sciences alongside Computer Science and Engineering underscores that digital deception cannot be treated purely as a software or algorithmic problem. However, the prominent interdisciplinary footprint highlights that the long-term success in combating digital deception depends on effective synergy between AI innovations and social science perspectives.

2.1. DEFINITION AND TYPES OF DISINFORMATION

In everyday conversation, phrases like „fake news“, „disinformation“, and „misinformation“ are frequently used synonymously, yet there are significant conceptual differences between them.

UNESCO (UNESCO n.d.) distinguishes the difference between the disinformation and misinformation based on the presence/absence of intention. Misinformation has a neutral or

positive underlying intent, whereas disinformation is characterized as the intention to deceive. According to the United Nations (n.d.) the misinformation is accidental spread of inaccurate information, whereas disinformation is not only inaccurate, but also intended to deceive and is spread in order to do serious harm. It has the potential to affect a broad range of human rights, undermining responses to public policies or amplifying tensions in times of emergency or armed conflict.

Wardle and Derakhshan (2017) introduce a new conceptual framework for examining information disorder, identifying the three different types: mis-, dis- and mal-information.

- Mis-information occurs when false information is shared, but no harm is meant.
- Dis-information occurs when false information is knowingly shared to cause harm.
- Mal-information occurs when information is shared to cause harm, often by moving information designed to stay private into the public sphere.

3. THE ROLE OF AI IN DISINFORMATION DETECTION

Fact-checking is currently one of the fundamental mechanisms for defending democratic public discourse against disinformation and fake news. However, behind the seemingly simple process of „verifying whether something is true“ lies a complex methodological and technological discipline that has evolved over decades and undergone a radical transformation in the digital age.

3.1. FACT-CHECKING

The term fact-checking means the process of verifying the accuracy of claims, statements or content that has been published or is intended to be published. Standard methodological tools of the classic fact-checker include (Ireton & Posetti 2018) (1) finding fact-checkable claims, (2) finding the facts and (3) correcting the record.

In today's digital age, a vibrant community of fact-checking portals has emerged that are available to all internet users, and some of the most important are:

- PolitiFact - evaluates claims through a review of other fact-checking sources, Google searches, searching online databases, consulting experts, and literature review (Holan & Sanders 2026),
- FactCheck.org - SciCheck function, which deals exclusively with false and misleading claims on scientific issues such as climate change, vaccines and medical treatments (FactCheck.org, n.d.),
- Snopes - focuses on urban legends, journalistic stories and memes circulating on the Internet (Snopes.com, n.d.),
- Full Fact - fact-checking organization that applies innovative automation tools to speed up the verification process (Full Fact n.d.),
- Google Fact Check Tools and ClaimReview standard: Google Fact Check Explorer aggregates fact-checks from thousands of trusted sources and allows you to search for specific claims. ClaimReview schema is a standardized format that fact-checking organizations add to their content, and which Google uses to recognize and display fact-checks directly in the search results (Google Fact Check Tools Recents n.d.).

The most significant development in digital fact-checking is the application of natural language processing (NLP) and machine learning methods to automate key steps of the fact-checking

process. Guo, Schlichtkrull and Vlachos (2022) describe a general NLP framework for automated fact-checking that consists of three phases:

- Claim detection: identification of claims within the text that are factually checkable and relevant,
- Evidence retrieval: finding relevant sources, databases and evidence that support or refute the claim,
- Claim verification: evaluating the accuracy of the claim based on the evidence found, whereby the system assigns a decision such as supporting, refuting or insufficient evidence.

In recent years, large language models (LLMs) such as GPT-4 have received a lot of attention for their potential for automated fact checking. The study by Quelle and Bovet (2024), evaluated GPT-3.5 and GPT-4's fact-checking capabilities on the PolitiFact dataset as well as a multilingual dataset. The findings revealed that GPT-4 beat GPT-3.5 in fact-checking tasks, particularly zero-shot reasoning tasks. The future of fact-checking is distinguished by an ever-increasing integration of AI tools into factographers' daily work, although this process is neither straightforward nor clear. Wolfe and Mitra (2024) found that generative AI is already transforming factographers' jobs, but in diverse ways depending on the organization's size and infrastructure. Larger firms utilize AI to automate everyday operations such as translation and database searches, but smaller organizations consider AI as an experimental tool rather than a dependable day-to-day support.

4. EMPIRICAL EVALUATION OF AI-ASSISTED FACT-CHECKING TOOLS

4.1. METHODOLOGY

This section reports an exploratory pilot comparison of three AI-assisted fact-checking tools. Given the very small and unbalanced sample described below, the results should be read as illustrative of qualitative failure patterns rather than as statistical performance.

Claim selection. The 12 claims analyzed here are a representative subset of a larger 20-claim dataset originally compiled for the first author's undergraduate thesis (Vidak, 2026), all previously fact-checked by certified organizations (Snopes.com, PolitiFact.com, EuvsDisinfo.eu). From the original 20 claims, which also included a crime category and two sport/political satirical items, 12 were retained for the present analysis by excluding the crime category and both satirical items, so that the ground truth for every remaining claim could be expressed on a strict binary True/False scale suitable for standard classification metrics (Table 3). The retained claims span five thematic categories: Politics (4 claims), Health/Medicine (5 claims), War & Geopolitics (1 claim), Natural Disasters/Climate (1 claim), and Urban Myths/Legends (1 claim), with a ground-truth distribution of 9 False and 3 True claims. Ground truth for every claim was taken directly from the certified fact-checking organization's own published verdict, not from the author's independent judgment. This dependency is discussed further in Section 6.

Tools and versions. The three tools were tested in June 2026, through their public consumer web interfaces: ChatGPT (GPT-4o, OpenAI, chat.openai.com), Claude (Anthropic, claude.ai), and Google Fact Check Tools Explorer (a search interface over the Claim Review-tagged database of certified fact-checkers, with no user-configurable settings).

Prompt and procedure. Both LLMs received an identical, standardized prompt for every claim: „Analyze the following claim and assess whether it is: (1) True, (2) False, (3) Partially true, (4) Satire, or (5) Cannot determine. Write a justification of 3-5 sentences, then give the final verdict in the format STATUS: [one of the five options].“ For Google FCTE, 3-6 English keywords drawn from each claim were entered into the search interface, and the number and verdict of any matching fact-checks were recorded; „no result“ was logged whenever the search returned nothing.

Coding criteria. Each tool’s output for each claim was scored on a three-level scale: ✓ if the verdict category matched the certified ground truth exactly, ~ if the tool correctly recognized that the claim was not straightforwardly true but assigned an imprecise or hedged category (for example, „partially true“ instead of a clear „false“), or X if the verdict was incorrect, contradicted the ground truth, or the tool returned „cannot determine“ / no result. In this 12-claim subset every score resolved to either ✓ or X, no ~ scores occurred, a point that corrects an inconsistency in an earlier draft of this paper (see Table 1 note below).

4.2. RESULTS

Table 1 presents the verdict and score for each tool on all 12 claims.

Table 1. Tool verdicts vs. ground truth (N = 12 claims).

ID	Claim	Category	Ground Truth	ChatGPT		Claude		Google FCTE	
				verdict	hit	verdict	hit	found?	hit
1	Trump standing next to alien-like figures	Politics	FALSE	FALSE	✓	FALSE	✓	(2) f-c	✓
2	Trump says cognitive test shows “extreme intelligence”	Politics	FALSE	TRUE	X	TRUE	X	(2) f-c	✓
3	Zelensky is a drug addict	Politics	FALSE	FALSE	✓	FALSE	✓	(1) f-c	✓
4	Trump “Voting in California is rigged”	Politics	FALSE	FALSE	✓	TRUE	X	(0) f-c	X
5	Inventor of Lobotomy received a Nobel Prize	Health/Med	TRUE	TRUE	✓	TRUE	✓	(1) f-c	✓
6	A veterinary company is developing pill to expand lifespan of a dog	Health/Med	TRUE	TRUE	✓	TRUE	✓	(1) f-c	✓
7	The U.S. takes 87% of all prescription medications in the world	Health/Med	FALSE	FALSE	✓	FALSE	✓	(1) f-c	✓
8	Russia announced its free mRNA cancer vaccine is ready for clinical use	Health/Med	FALSE	TRUE	X	TRUE	X	(4) f-c	✓
9	COVID-19 mRNA vaccine helped extend cancer survival	Health/Med	TRUE	TRUE	✓	TRUE	✓	(0) f-c	X

10	Zelensky “started” the war in Ukraine	War/Geop.	FALSE	FALSE	✓	FALSE	✓	(1) f-c	✓
11	Animals flee Yellowstone, supervulcano eruption	Natural disasters	FALSE	FALSE	✓	FALSE	✓	(2) f-c	✓
12	Earthquakes mostly happen when the weather is hot and dry	Urban Myths	FALSE	FALSE	✓	FALSE	✓	(1) f-c	✓

Note. ✓ = verdict matches ground truth; X = verdict incorrect, contradicts ground truth, or no result returned, no ~ (partial) scores occurred in this subset. Google FCTE returned no result for claims ID 4 and ID 9 (marked „not found“), for the remaining 10 claims it covered, every verdict matched the certified ground truth.


Table 2 separates two properties that are easily conflated when comparing a generative tool against a database-lookup tool: coverage (the share of claims for which a tool produces any definitive verdict) and accuracy (the share of claims correctly classified). ChatGPT and Claude always produced a definite verdict in this subset (100% coverage), so their conditional and unconditional accuracy coincide. Google FCTE covered only 10 of 12 claims (83.3%) but was correct on all 10, giving it a much higher conditional accuracy (100%) than its unconditional accuracy (83.3%, which treats the two uncovered claims as errors, consistent with Figure 3).

Table 2. Coverage and accuracy per tool.

Tool	Coverage	Unconditional accuracy (N=12)	Conditional accuracy (covered claims only)
ChatGPT	100% (12/12)	83.3% (10/12)	83.3% (10/12)
Claude	100% (12/12)	75.0% (9/12)	75.0% (9/12)
GoogleFCTE	83.3% (10/12)	83.3% (10/12)	100% (10/10)

4.3. COMPARATIVE ANALYSIS

Figure 3: Tool performance on 12-Claim Sample



Across the sample, ChatGPT and Google FCTE both achieved an unconditional accuracy of 83% (10 of 12 claims correctly identified), while Claude reached 75% (9 of 12). A closer look at the nature of the errors, however, reveals important qualitative differences between the tools. ChatGPT's two failures were both instances of the same underlying problem. For claim ID 2 (the Trump cognitive-test claim), it returned a „True“ verdict because the underlying quotation was accurate, but it failed to recognize the broader context, that a cognitive-screening test does not measure general intelligence. This is a textbook case of contextual manipulation: a statement that is literally accurate but pragmatically misleading. ChatGPT made the identical error on claim ID 8 (the Russian mRNA cancer-vaccine claim), again treating an official announcement at face value rather than checking whether the underlying development had occurred.

Claude's three incorrect verdicts were concentrated in Politics and Health/Medicine: claim ID 2 (the same contextual failure as ChatGPT), claim ID 8 (the same vaccine-announcement claim), and claim ID 4 (the California-voting claim), where Claude returned an incorrect „True“ verdict instead of „False.“ This is a full miss (X), not a partial match. No ~ scores occurred anywhere in this subset. Despite its lower headline accuracy, Claude was the only LLM that never returned an inconclusive „cannot determine“ response; it consistently issued a definite verdict, even while acknowledging uncertainty in its reasoning. This behavior, also observed across the fuller 20-claim dataset reported in the accompanying thesis (Vidak, 2026), makes Claude more predictable and, arguably, more operationally reliable as a fact-checking assistant, even where its headline accuracy is lower.

Google FCTE matched ChatGPT's 83% unconditional accuracy, but its two „failures“ were of a structurally different kind: for claims ID 4 and ID 9, the tool returned no result at all, a complete absence of data rather than a wrong verdict. As Table 2 shows, this makes Google FCTE the most precise tool of the three when it does return an answer (conditional accuracy of 100%), but one whose usefulness is entirely dependent on whether a claim has already been verified and indexed by a certified fact-checking organization.

Category-level results (not shown as a separate table, given the small per-category counts) suggest that Health/Medicine (4/5 correct for both LLMs and for FCTE) and the single-claim categories of War/Geopolitics, Natural Disasters, and Urban Myths (1/1 for all three tools) were handled reliably. Politics was the most challenging category, with ChatGPT and Google FCTE each scoring 3/4 and Claude 2/4; errors clustered around claims involving contextual framing or very recent events. Given that each of these categories is based on only one to five claims, these patterns should be read as suggestive rather than conclusive.

Table 3 complements the accuracy figures above with standard classification metrics precision, recall, F1, and macro-F1, treating „False“ (i.e., disinformation) as the positive class.

Table 3. Results analysis per tool.

Tool	N covered	TP	FP	TN	FN	Precision	Recall	F1 (False)	Macro-F1
ChatGPT	12	7	0	3	2	1.00	0.78	0.88	0.81
Claude	12	6	0	3	3	1.00	0.67	0.80	0.73
GoogleFCTE	10	8	0	2	0	1.00	1.00	1.00	1.00

Note. TP/FP/TN/FN = true/false positives/negatives. Precision, recall, and F1 are reported for the „False“ class; macro-F1 is the unweighted mean of the F1 scores for the „False“ and „True“ classes. Because ChatGPT and Claude never abstained in this subset, their metrics are computed over all 12 claims, Google FCTE's metrics are computed only over the 10 claims it

covered (see Table 2 for coverage) its perfect scores reflect 100% accuracy on that covered subset, not on all 12 claims. Given the very small and unbalanced class sizes (9 False vs. 3 True), these figures should be read as illustrative of each tool's error profile rather than as precise, generalizable estimates

5. DISCUSSION

Within the limits of this small, exploratory sample, no single tool was sufficient on its own. Each tool excelled on a different dimension but failed in at least one systematic way. ChatGPT and Google FCTE achieved the same unconditional accuracy (83%), but for different reasons and with different failure modes: ChatGPT failed on contextually complex claims, while Google FCTE failed only when a claim was not yet indexed in its database, never by giving an incorrect verdict. Claude (75%) was the most behaviorally consistent LLM: it never returned an inconclusive verdict, instead explicitly qualifying uncertain answers, which may be operationally valuable in a production fact-checking workflow even when headline accuracy is somewhat lower. Google FCTE was the most precise tool when data existed for a claim (100% conditional accuracy), but was entirely unavailable for two of the twelve claims recent, regional, or otherwise not-yet-certified content. Contextual manipulation was the hardest failure mode for both LLMs: claims that are literally accurate but pragmatically misleading evaded correct classification and, in principle, require human contextual judgement to resolve reliably. Within this small sample, a human-in-the-loop approach in which AI tools handle routine claim retrieval and an initial classification pass, while experienced fact-checkers make the final call on complex or sensitive cases remains the most defensible model of responsible AI-assisted fact-checking.

6. LIMITATIONS

The empirical comparison reported here carries several important limitations that should be considered when interpreting the results:

- Sample size and generalizability. With only 12 claims, the accuracy, precision, recall, and F1 figures in Tables 2 and 3 are illustrative of qualitative failure patterns, not statistically robust or generalizable performance benchmarks, the results should be read as an exploratory pilot study.
- Single testing round. Each claim was submitted once per tool, because LLM outputs can vary between runs, the reported verdicts may not be perfectly reproducible on repeated testing.
- Single coder. Scoring against the certified ground truth was performed by a single author, without an independent second coder or a formal inter-rater reliability check.
- Language and source scope. All claims and prompts were in English, and the underlying claim database draws predominantly on US/English-language fact-checking organizations (Snopes, PolitiFact) plus one EU-focused source (EUvsDisinfo), the findings may not generalize to other languages or fact-checking ecosystems.

Future work should replicate this comparison on a substantially larger and better-balanced sample, ideally with multiple independent coders, fixed and disclosed model versions accessed via API, and claims drawn from a broader set of languages and fact-checking traditions.

7. CONCLUSION

Rapid technological innovations and the advent of generative AI have fundamentally changed the global information ecosystem. While these tools increase access to knowledge, they also speed the creation and dissemination of sophisticated digital disinformation, deepfakes, and manipulative content on a massive scale. This study investigated current research trends in disinformation/misinformation and examined the use of AI as a protective tool. The findings show that, while AI has excellent automated capabilities for early claim retrieval, source verification, and pattern detection, it cannot function well in isolation.

The standard for responsible fact-checking is to use AI technologies to conduct routine data gathering and basic content classification, leaving final verdicts and contextual interpretations to experienced journalists and subject matter experts. To protect online information integrity, future initiatives must prioritize improving AI detection accuracy, encouraging cross-sector collaboration between research institutions and media organizations, and constantly modifying methodological norms to keep up with evolving technology challenges.

ACKNOWLEDGEMENT

This work is supported by the project „HeyAIdé - Health Empowerment for You through AI Direct Engagement“ co-funded by the European Union from the European Regional Development Fund.

REFERENCES

1. Adams, Z., Osman, M., Bechlivanidis, C., & Meder, B. (2023). (Why) Is misinformation a problem? *Perspectives on Psychological Science*, 18(6), 1436–1463. <https://doi.org/10.1177/17456916221141344>
2. Aïmeur, E., Amri, S., & Brassard, G. (2023). Fake news, disinformation and misinformation in social media: A review. *Social Network Analysis and Mining*, 13(1), 30. <https://doi.org/10.1007/s13278-023-01028-5>
3. European Court of Auditors. (2020). *EU Action Plan against Disinformation Audit Preview Information on an Upcoming Audit*.
4. FactCheck.org. (n.d.). Our process. Retrieved July 22, 2026, from <https://www.factcheck.org/our-process/>
5. Full Fact. (n.d.). Full Fact: The UK's independent fact-checking organisation. Retrieved July 22, 2026, from <https://fullfact.org/>
6. Google. (n.d.). Google Fact Check Tools: Recent claims. Retrieved July 22, 2026, from <https://toolbox.google.com/factcheck/explorer/search/list:recent;hl=en>
7. Guo, Zhijiang, Michael Schlichtkrull, and Andreas Vlachos. 2022. A Survey on Automated Fact-Checking. *Transactions of the Association for Computational Linguistics* 10:178–206. doi:10.1162/TACL_A_00454/109469.
8. Holan, A. D., & Sanders, K. (2026). The principles of the Truth-O-Meter: PolitiFact's methodology for independent fact-checking. PolitiFact. Retrieved July 22, 2026, from <https://politifact.com/article/2018/feb/12/principles-truth-o-meter-politifact-methodology-i/>
9. Ireton, C., & Posetti, J. (Eds.). (2018). *Journalism, 'fake news' and disinformation: Handbook for journalism education and training*. UNESCO. Retrieved July 22, 2026,

- from <https://unesdoc.unesco.org/ark:/48223/pf0000265552>
10. Le, L. H. (2026). Information sharing intention or sharing avoidance? Impacts of fake news risk perceptions and personal capabilities under the lens of the situational awareness theory. *Online Information Review*, 50(2), 307–331. <https://doi.org/10.1108/OIR-07-2024-0462>
 11. Olan, F., Jayawickrama, U., Arakpogun, E. O., Suklan, J., & Liu, S. (2022). Fake news on social media: The impact on society. *Information Systems Frontiers*, 26(2), 443–458. <https://doi.org/10.1007/s10796-022-10242-z>
 12. Orhan, A. (2023). Fake news detection on social media: The predictive role of university students' critical thinking dispositions and new media literacy. *Smart Learning Environments*, 10(1), Article 29. <https://doi.org/10.1186/s40561-023-00248-8>
 13. Pérez-Escolar, M., Lilleker, D., & Tapia-Frade, A. (2023). A systematic literature review of the phenomenon of disinformation and misinformation. *Media and Communication*, 11(2), 76–87. <https://doi.org/10.17645/mac.v11i2.6453>
 14. Poushter, J., Fagan, M., Smerkovich, M., & Prozorovsky, A. (2025). *International opinion on global threats: False information, global economy and terrorism seen as major threats*. Pew Research Center. Retrieved July 22, 2026, from <https://www.pewresearch.org>
 15. Quelle, D., & Bovet, A. (2024). The perils and promises of fact-checking with large language models. *Frontiers in Artificial Intelligence*, 7, 1341697. <https://doi.org/10.3389/frai.2024.1341697>
 16. Snopes. (n.d.). *Snopes.com: The definitive fact-checking site*. Retrieved July 22, 2026, from <https://www.snopes.com/>
 17. Statista. (n.d.). *Misinformation on social media - Statistics & facts*. Retrieved July 22, 2026, from <https://www.statista.com/topics/9713/misinformation-on-social-media/#topicOverview>
 18. UNESCO. (n.d.). *What is disinformation? Meaning, definition*. Retrieved July 29, 2026, from <https://www.unesco.org/en/query-list/d/disinformation>
 19. United Nations. (n.d.). *Countering disinformation*. Retrieved July 29, 2026, from <https://www.un.org/en/countering-disinformation>
 20. Wardle, C., & Derakhshan, H. (2017). *Information disorder: Toward an interdisciplinary framework for research and policymaking* (Council of Europe Report No. DGI(2017)09). Council of Europe. Retrieved July 22, 2026, from <https://www.coe.int>
 21. Wolfe, R., & Mitra, T. (2024). The impact and opportunities of generative AI in fact-checking. *Proceedings of the 2024 ACM Conference on Fairness, Accountability, and Transparency (FAccT '24)*, 1531–1543. <https://doi.org/10.1145/3630106.3658987>
 22. World Economic Forum. (2024). *The global risks report 2024* (19th ed.). Retrieved July 22, 2026, from https://www3.weforum.org/docs/WEF_The_Global_Risks_Report_2024.pdf
 23. Yu, H., Alivi, M. A. B. A., & Wu, L. (2026). False news sharing behavior on social media: A systematic review of user-centered perspectives. *Studies in Media and Communication*, 14(3), 353–366. <https://doi.org/10.11114/smc.v14i3.8595>

KONCEPTUALNI MODEL DIGITALNE TRANSFORMACIJE PROCESA IZRADE B2B PONUDA OSIGURANJA

SUZANA KEGLEVIĆ KOZJAK

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

TANJA ŠESTANJ-PERIĆ

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

IVANA ĐURDEK

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

SAŽETAK

Proces izrade B2B ponuda u osiguravajućim društvima obilježen je složenim postupcima prikupljanja podataka, procjene rizika i konfiguriranja proizvoda, što često rezultira dugotrajnim i administrativno zahtjevnim procesima. Cilj je rada analizirati mogućnosti primjene umjetne inteligencije i Configure-Price-Quote (CPQ) sustava u digitalnoj transformaciji procesa izrade B2B ponuda osiguranja poslovnim klijentima te razviti konceptualni TO-BE model koji integrira automatiziranu procjenu rizika, konfiguriranje proizvoda i generiranje ponuda. Istraživanje se temelji na analizi znanstvene i stručne literature, analizi poslovnih procesa te pregledu dostupnih industrijskih rješenja i javno dostupnih informacija o poslovanju osiguravajućih društava. Razvijeni model uključuje primjenu umjetne inteligencije za klasifikaciju zahtjeva, procjenu rizika, personalizaciju ponuda, predviđanje vjerojatnosti prihvaćanja ponude i preporuku optimalnih proizvoda. Rezultati provedene analize upućuju na to da konceptualni model temeljen na integraciji umjetne inteligencije i CPQ sustava ima potencijal unaprijediti učinkovitost procesa izrade B2B ponuda smanjenjem vremena obrade zahtjeva, automatizacijom administrativnih aktivnosti, povećanjem točnosti procjene rizika te poboljšanjem kvalitete i razine personalizacije korisničkih ponuda. Predloženi model predstavlja temelj za buduća empirijska istraživanja i razvoj inteligentnih sustava za digitalnu transformaciju poslovnih procesa u osiguravajućoj industriji.

KLJUČNE RIJEČI: umjetna inteligencija, B2B osiguranje, Configure-Price-Quote (CPQ), digitalna transformacija, procjena rizika

1. UVOD

Digitalna transformacija posljednjih je godina značajno promijenila način poslovanja organizacija u gotovo svim gospodarskim sektorima, pri čemu umjetna inteligencija postaje jedan od ključnih pokretača automatizacije, optimizacije poslovnih procesa i razvoja novih poslovnih modela. Posebno se ističe njezina primjena u djelatnostima koje raspolažu velikim količinama podataka i zahtijevaju donošenje složenih odluka, među kojima važnu ulogu ima i osiguravajuća industrija.

Osiguravajuća društva u segmentu poslovnih korisnika nude širok spektar proizvoda kojima se pokrivaju različiti poslovni rizici, uključujući osiguranje imovine, odgovornosti, zaposlenika, transporta i drugih oblika zaštite poslovanja (Allianz Hrvatska, 2026; Generali Hrvatska, 2026; GRAWE Hrvatska, 2025; Wiener Osiguranje, 2026). Za razliku od standardiziranih proizvoda osiguranja namijenjenih fizičkim osobama, osiguranje pravnih osoba odnosno poslovnih klijenata zahtijeva prikupljanje i obradu većeg broja podataka o poduzeću, procjenu specifičnih poslovnih rizika, određivanje odgovarajućih osigurateljskih pokrića te izračun premije. U radu se za poslovanje i ponude namijenjene pravnim osobama koristi oznaka B2B (*engl. business-to-business*). Takav proces često uključuje velik broj ručnih aktivnosti, komunikaciju između više sudionika i izradu više verzija ponuda, što može rezultirati duljim vremenom obrade, većim operativnim troškovima i povećanom mogućnošću pogrešaka.

Razvoj umjetne inteligencije i sustava za konfiguriranje proizvoda, određivanje cijene i izradu ponude (*engl. Configure-Price-Quote – CPQ*) otvara mogućnost digitalne transformacije procesa izrade B2B ponuda kroz automatizaciju prikupljanja i obrade podataka, procjenu rizika, konfiguriranje proizvoda, izračun premije te generiranje personaliziranih ponuda. Integracija ovih tehnologija može pridonijeti povećanju učinkovitosti poslovnih procesa, kvalitetnijoj procjeni rizika i unapređenju korisničkog iskustva, uz istodobno smanjenje administrativnog opterećenja zaposlenika.

Cilj je rada analizirati mogućnosti primjene umjetne inteligencije i CPQ sustava u procesu izrade B2B ponuda osiguranja poslovnim klijentima te razviti konceptualni TO-BE model digitaliziranog procesa. Poseban naglasak stavljen je na mogućnosti automatizirane procjene rizika, personalizacije ponuda, preporuke optimalnih proizvoda te automatizacije pojedinih aktivnosti u procesu izrade ponuda.

Rad je strukturiran u pet poglavlja. Nakon uvoda prikazana je metodologija istraživanja. Treće poglavlje razmatra mogućnosti primjene umjetne inteligencije u procesu izrade B2B ponuda osiguranja. U četvrtom poglavlju razvijen je konceptualni TO-BE model koji integrira umjetnu inteligenciju i CPQ sustav u proces izrade ponuda. U završnom poglavlju izneseni su zaključci, ograničenja istraživanja te smjernice za buduća istraživanja.

2. METODOLOGIJA ISTRAŽIVANJA

Istraživanje se temelji na kvalitativnom istraživačkom pristupu primjenom analize i sinteze znanstvene i stručne literature iz područja osiguranja, umjetne inteligencije, digitalne transformacije i CPQ sustava. Uz znanstvenu i stručnu literaturu analizirani su javno dostupni izvori povezani s poslovanjem osiguravajućih društava, uključujući njihove službene mrežne stranice i dostupne poslovne materijale, kao i relevantna industrijska i stručna izvješća. Dodatno je proveden intervju s predstavnikom osiguravajućeg društva, kojim su prikupljeni uvidi u postojeći proces izrade B2B ponuda, ključne aktivnosti sudionika u procesu te način

prikupljanja i obrade podataka relevantnih za izradu ponude. Navedeni izvori korišteni su za identifikaciju karakterističnih podataka potrebnih za izradu ponuda osiguranja poslovnim klijentima, uobičajenih aktivnosti u procesu ugovaranja te mogućih područja primjene digitalnih tehnologija. Za potrebe oblikovanja konceptualnog modela korišteni su i izvori koji opisuju funkcionalnosti umjetne inteligencije i CPQ sustava. Na temelju prikupljenih spoznaja provedena je analiza postojećeg procesa izrade B2B ponuda te je razvijen konceptualni TO-BE model koji prikazuje mogućnosti integracije umjetne inteligencije u postupke procjene rizika, konfiguriranja proizvoda i generiranja ponuda. Budući da interni poslovni procesi osiguravajućih društava nisu javno dostupni, predloženi model predstavlja konceptualni prikaz tipičnog procesa izrade B2B ponuda temeljen na dostupnoj literaturi i primjerima dobre poslovne prakse.

3. ULOGA UMJETNE INTELIGENCIJE U IZRADI B2B PONUDA

Posljednjih nekoliko godina umjetna inteligencija postaje jedan od ključnih pokretača digitalne transformacije u djelatnosti osiguranja. Za razliku od tradicionalnih sustava koji se primarno koriste za analizu podataka i automatizaciju pojedinih aktivnosti, generativna umjetna inteligencija omogućuje stvaranje novih sadržaja i poslovnih rješenja na temelju raspoloživih podataka. U procesu izrade B2B ponuda njezina se primjena očituje u personalizaciji proizvoda, podršci prodajnim aktivnostima, optimizaciji procjene rizika i određivanja cijena te u automatiziranom generiranju ponuda. Takve mogućnosti mogu pridonijeti učinkovitijem donošenju odluka i komunikaciji s poslovnim klijentima (Colaco, 2024). Uz to, omogućuje se preporuka proizvoda s najvećom vjerojatnošću prihvatanja, što može unaprijediti korisničko iskustvo i povećati stopu konverzije prodajnih prilika u ugovorene police osiguranja.

Colaco (2024) također ističe da primjena generativne umjetne inteligencije može povećati profitabilnost osiguravajućih društava, smanjiti operativne troškove i unaprijediti učinkovitost poslovnih procesa analizom podataka o klijentu, djelatnosti, vrijednosti imovine, povijesti šteta i drugih relevantnih čimbenika. U osigurateljskom kontekstu posebno se ističe potreba za povezivanjem različitih primjena generativne umjetne inteligencije u cjelovita rješenja koja uzimaju u obzir specifičnosti djelatnosti. U kontekstu ovog rada navedene se mogućnosti promatraju prvenstveno kroz njihovu primjenu u procesu izrade B2B ponuda osiguranja.

Razvoj umjetne inteligencije mijenja tradicionalni pristup osiguranju iz modela „otkrij i popravi“ (*engl. Detect & Repair*) prema modelu „predvidi i spriječi“ (*engl. Predict & Prevent*), pri čemu se donošenje odluka sve više temelji na analizi velikih količina podataka. Primjena senzorskih tehnologija, interneta stvari (*engl. Internet of Things – IoT*) i drugih digitalnih izvora omogućuje osiguravateljima preciznije razumijevanje poslovnih klijenata, razvoj novih proizvoda te personalizirano određivanje premija osiguranja. Balasubramanian et al. (2021) naglašavaju kako upravo rast količine dostupnih podataka omogućuje razvoj personaliziranih modela određivanja premija i kvalitetniju procjenu rizika. Takav je pristup posebno značajan u poslovnim osiguranjima, u kojima se ponude temelje na velikom broju varijabli, uključujući djelatnost poduzeća, vrijednost imovine, broj zaposlenika, lokacije poslovanja, povijest šteta i regulatorne zahtjeve. Integracijom umjetne inteligencije moguće je automatizirati procjenu rizika i konfiguriranje proizvoda te generirati više prilagođenih paketa osiguranja za pojedinog klijenta. Istodobno, personalizirane ponude mogu povećati percepciju vrijednosti proizvoda i pozitivno utjecati na vjerojatnost sklapanja ugovora.

Unatoč brojnim prednostima, primjena umjetne inteligencije u djelatnosti osiguranja otvara i pitanja transparentnosti donošenja odluka, zaštite podataka te mogućih pristranosti modela. Zbog toga je potrebno uspostaviti odgovarajuće mehanizme upravljanja rizicima i osigurati ljudski nadzor nad ključnim poslovnim odlukama kako bi se povećalo povjerenje u primjenu inteligentnih sustava (Colaco, 2024).

Umjetna inteligencija pritom ne predstavlja zamjenu za stručnjake, već alat koji povećava njihovu učinkovitost i kvalitetu donošenja odluka. Davenport i Ronanki (2018) ističu kako organizacije najveću vrijednost ostvaruju kada umjetna inteligencija i zaposlenici djeluju komplementarno, pri čemu tehnologija preuzima rutinske i podatkovno intenzivne aktivnosti, dok ljudi ostaju odgovorni za složene procjene, komunikaciju s korisnicima i donošenje konačnih odluka. U području B2B osiguranja takav pristup omogućuje da umjetna inteligencija služi kao podrška u analizi podataka, procjeni rizika i pripremi ponuda, dok stručnjaci za procjenu i prihvata rizika (*engl. underwriters*) zadržavaju ključnu ulogu u procjeni nestandardnih i visokorizičnih slučajeva. Suradnja čovjeka i umjetne inteligencije povećava produktivnost, ubrzava obradu zahtjeva i poboljšava kvalitetu procesa izrade ponuda (Davenport & Ronanki, 2018).

Automatizacijom administrativnih aktivnosti prodajni predstavnici mogu manje vremena posvetiti rutinskim poslovima, a više savjetovanju klijenata i razvoju dugoročnih poslovnih odnosa. Kako ističu Davenport i Ronanki (2018), organizacije koje uspješno implementiraju umjetnu inteligenciju, tehnologiju ne promatraju kao zamjenu za zaposlenike, već kao sredstvo za povećanje njihove učinkovitosti i stvaranje dodatne vrijednosti za korisnike. Takav pristup predstavlja temelj razvoja suvremenih digitalnih procesa izrade B2B ponuda osiguranja.

4. KONCEPTUALNI TO-BE MODEL TEMELJEN NA UMJETNOJ INTELIGENCIJI I CPQ SUSTAVU

U ovom se poglavlju prikazuje konceptualni TO-BE model koji integrira umjetnu inteligenciju i Configure-Price-Quote (CPQ) sustav u proces izrade B2B ponuda osiguranja (Slika 1). Model predstavlja ciljno (TO-BE) stanje procesa nakon predložene digitalne transformacije, odnosno način na koji bi proces izrade B2B ponuda mogao biti organiziran uz primjenu umjetne inteligencije i CPQ sustava. Predloženi model nije empirijski testiran u stvarnom poslovnom okruženju, već predstavlja konceptualni okvir razvijen na temelju znanstvene i stručne literature te poslovnih procesa. Budući da interni procesi osiguravajućih društava nisu javno dostupni, pojedini elementi modela temelje se na pretpostavkama autorica i dostupnim primjerima industrijske prakse.

Konceptualni model razvijen je na temelju sinteze literature, javno dostupnih poslovnih materijala osiguravajućih društava te intervjua provedenog s predstavnikom osiguravajućeg društva. Na taj je način dobiven uvid u postojeći proces izrade B2B ponuda i u njegove sudionike. Navedeni uvidi povezani su sa spoznajama o mogućnostima primjene umjetne inteligencije i CPQ sustava.

Analizom znanstvene i stručne literature identificirane su ključne aktivnosti procesa izrade ponuda osiguranja poslovnim klijentima i mogućnosti njihove digitalizacije. Posebno su razmotrene aktivnosti prikupljanja i validacije podataka, klasifikacije zahtjeva, procjene rizika, odabira proizvoda, izračuna premije i generiranja ponude. Navedene aktivnosti povezane su s funkcionalnostima CPQ sustava i umjetne inteligencije identificiranim u analiziranim


izvorima. Na toj je osnovi oblikovan konceptualni ciljni model procesa kao autorska sinteza identificiranih aktivnosti i mogućnosti njihove digitalne podrške.

Proces izrade B2B ponude započinje unosom podataka putem digitalnog obrasca koji ispunjava klijent. Nakon zaprimanja zahtjeva umjetna inteligencija analizira unesene informacije, prepoznaje djelatnost, vrstu osiguranja, potrebna pokrića i ostale relevantne podatke. Model umjetne inteligencije pritom koristi podatke o djelatnosti, vrijednosti imovine, lokaciji poslovanja, povijesti šteta i financijskim pokazateljima kako bi procijenio razinu rizika i predložio odgovarajuća pokrića. Na temelju rezultata CPQ sustav automatski konfigurira proizvod, predlaže odgovarajuće vrste osiguranja, uključujući osiguranje imovine, strojeva, odgovornosti i zaposlenika, izračunava premiju te generira više mogućih paketa osiguranja.

Uloga umjetne inteligencije u predloženom modelu obuhvaća analizu zahtjeva, prepoznavanje rizika, preporuku proizvoda koji najbolje odgovaraju profilu klijenta te odabir paketa s najvećom vjerojatnošću prihvatanja. Odluke se temelje na podacima koje dostavlja klijent, kao i na raspoloživim povijesnim podacima i obrascima ponašanja sličnih poslovnih subjekata. Na temelju tih informacija sustav preporučuje optimalan paket osiguranja prilagođen karakteristikama i potrebama pojedinog poslovnog klijenta.

Ulazne podatke potrebne za izradu B2B ponude i procjenu rizika čine naziv i djelatnost poduzeća, OIB, broj zaposlenika, godišnji prihod, vrijednost imovine, broj vozila, povijest šteta te postojeće police osiguranja. Na temelju tih podataka sustav generira procjenu rizika, izračun premije, rok valjanosti ponude, prijedlog ponude i prijedlog police osiguranja.

Slika 1. Konceptualni ciljni model digitaliziranog procesa izrade B2B ponude osiguranja uz primjenu umjetne inteligencije i CPQ sustava



Izvor: Izradile autorice u alatu Mermaid.js.

U praksi se ESG kriteriji sve češće uključuju u procese upravljanja rizicima, određivanja premija i donošenja odluka u osiguravajućim društvima (Gatzert et al., 2020). Pregled literature pokazuje da se ESG kriteriji u osigurateljnoj djelatnosti najviše proučavaju upravo u kontekstu upravljanja rizicima, u koji se ugrađuju duž cijelog lanca vrijednosti rizika (Marti et al., 2024). U kontekstu B2B osiguranja podaci o obnovljivim izvorima energije, zdravlju i sigurnosti na radu te upravljanju ljudskim kapitalom mogu predstavljati vrijedan dodatni izvor informacija za procjenu rizika te pridonijeti kvalitetnijem određivanju premije i odabiru odgovarajućih pokrića (Aburto Barrera & Wagner, 2023; Gatzert et al., 2020). Stoga integracija ESG pokazatelja predstavlja jedan od mogućih smjerova razvoja budućih digitalnih sustava za automatiziranu izradu B2B ponuda osiguranja.

Zaključno, na temelju provedene analize literature razvijen je konceptualni TO-BE model u kojem umjetna inteligencija ima ključnu ulogu u klasifikaciji zahtjeva prema vrsti osiguranja, procjeni rizika, odabiru i preporuci optimalnog paketa osiguranja, preporuci dodatnih pokrića, predviđanju vjerojatnosti prihvaćanja ponude te prepoznavanju nepotpunih zahtjeva. Kako bi podržao navedene aktivnosti, sustav treba omogućiti unos i validaciju podataka poslovnog klijenta, automatsko dohvaćanje podataka iz internih i vanjskih izvora (npr. interne baze polica, FINA i bonitetne baze), upravljanje dokumentacijom, automatsku procjenu rizika i izračun premije, konfiguriranje i personalizaciju više paketa osiguranja, generiranje ponuda u formatu PDF, vođenje verzija ponuda, digitalno odobravanje i potpisivanje ugovora, praćenje statusa zahtjeva te generiranje izvještaja za potrebe prodaje i upravljanja rizicima.

Analiza dostupne literature i tržišnih rješenja upućuje na to da digitalizacija procesa izrade B2B ponuda može pridonijeti bržoj obradi zahtjeva, smanjenju operativnih troškova, manjoj mogućnosti pogrešaka te učinkovitijoj komunikaciji s poslovnim klijentima. Umjesto ručne obrade podataka i izrade ponuda, digitalni alati mogu značajno skratiti vrijeme izrade složenih ponuda, uz osiguravanje usklađenosti s važećim zakonodavstvom i centralizirano upravljanje podacima o klijentima. Dodatnu vrijednost pruža CPQ sustav koji omogućuje automatsko konfiguriranje proizvoda, izračun premije i generiranje ponuda, dok njegovom integracijom s umjetnom inteligencijom postaje moguće preporučiti optimalne pakete osiguranja, procijeniti vjerojatnost prihvaćanja ponude i predložiti dodatna pokrića prilagođena profilu poslovnog klijenta (Hanna, 2024; IBM, 2021).

5. ZAKLJUČAK

U radu su analizirane mogućnosti primjene umjetne inteligencije i Configure-Price-Quote (CPQ) sustava u procesu izrade B2B ponuda osiguranja poslovnim klijentima te je razvijen konceptualni TO-BE model digitaliziranog procesa. Predloženi model prikazuje način integracije umjetne inteligencije u aktivnosti klasifikacije zahtjeva, procjene rizika, konfiguriranja proizvoda, određivanja premije i generiranja personaliziranih ponuda.

Rezultati provedene analize upućuju na to da primjena umjetne inteligencije i CPQ sustava ima potencijal unaprijediti učinkovitost procesa izrade B2B ponuda smanjenjem vremena obrade zahtjeva, automatizacijom administrativnih aktivnosti, povećanjem točnosti procjene rizika te poboljšanjem kvalitete i razine personalizacije ponuda poslovnim klijentima. Istodobno, digitalizacija procesa može omogućiti učinkovitije donošenje odluka i bolju podršku zaposlenicima u složenim postupcima procjene rizika. Ograničenje rada proizlazi iz činjenice da predloženi model nije implementiran ni empirijski validiran u stvarnom poslovnom okruženju osiguravajućeg društva, već predstavlja konceptualni okvir razvijen na temelju

dostupne literature i analize javno dostupnih poslovnih materijala osiguravajućih društava te provedenog intervjua s predstavnikom osiguravajućeg društva o postojećem procesu izrade B2B ponuda. Pri oblikovanju modela uzete su u obzir spoznaje dobivene analizom navedenih izvora i intervjua, kao i spoznaje o mogućnostima primjene umjetne inteligencije i CPQ sustava u osiguranju, na temelju kojih su identificirane ključne aktivnosti procesa koje je moguće digitalizirati ili podržati primjenom navedenih tehnologija.

Buduća istraživanja trebala bi obuhvatiti razvoj i implementaciju prototipa sustava, analizu stvarnih poslovnih podataka te empirijsku evaluaciju učinaka primjene umjetne inteligencije na vrijeme izrade ponuda, kvalitetu procjene rizika, točnost određivanja premije i stopu prihvatanja ponuda. Uz navedeno, mogući je smjer daljnjih istraživanja uključivanje ESG pokazatelja u procese procjene rizika, osobito u segmentima osiguranja u kojima takvi pokazatelji mogu predstavljati relevantan izvor dodatnih informacija o klijentu i njegovoj izloženosti rizicima.

ZAHVALA

Ovaj rad izrađen je u okviru IRI S3 projekta PK.1.1.12.0030 „AI platforma nove generacije za sigurnu i održivu prodaju u složenim industrijama – Quoka CPQ“. Projekt je sufinanciran sredstvima Europske unije iz Europskog fonda za regionalni razvoj.

REFERENCE

1. Aburto Barrera, L. I., & Wagner, J. (2023). A systematic literature review on sustainability issues along the value chain in insurance companies and pension funds. *European Actuarial Journal*, 13, 653–701. Preuzeto 3. lipnja 2026. s: <https://doi.org/10.1007/s13385-023-00349-1>
2. Allianz Hrvatska. (2026). Moje poslovanje. Preuzeto 2. lipnja 2026. s: https://www.allianz.hr/hr_HR/poslovni-korisnici/zastitite-svoje-poslovanje/moje-poslovanje.html
3. Balasubramanian, R., Libarikian, A., & McElhaney, D. (2021). Insurance 2030—The impact of AI on the future of insurance. McKinsey & Company. Preuzeto 3. lipnja 2026. s: <https://www.mckinsey.com/industries/financial-services/our-insights/insurance-2030-the-impact-of-ai-on-the-future-of-insurance>
4. Colaco, J. (2024). Generative AI in insurance: Does artificial intelligence have a place in the insurance industry? Deloitte Insights. Preuzeto 11. lipnja 2026. s: <https://www.deloitte.com/global/en/industries/financial-services/perspectives/generative-ai-in-insurance.html>
5. Davenport, T. H., & Ronanki, R. (2018). Artificial intelligence for the real world. *Harvard Business Review*, 96(1), 108–116. Preuzeto 3. lipnja 2026. s: <https://hbr.org/2018/01/artificial-intelligence-for-the-real-world>
6. Gatzert, N., Reichel, P., & Zitzmann, A. (2020). Sustainability risks & opportunities in the insurance industry. *Zeitschrift für die gesamte Versicherungswissenschaft*, 109(3), 311–331. Preuzeto 3. lipnja 2026. s: <https://doi.org/10.1007/s12297-020-00482-w>
7. Generali Hrvatska. (2026). Pravne osobe. Preuzeto 2. lipnja 2026. s: <https://generalih.hr/pravne-osobe>
8. GRAWE Hrvatska. (2025). GRAWE osiguranje malog i srednjeg poduzetništva. Preuzeto 2. lipnja 2026. s:

- https://www.grawe.hr/fileadmin/grawe_hr/Downloads/Obrasci/Brosure_i_letci/GRAWE_osiguranje_malog_i_srednjeg_poduzetnistva.pdf
9. Hanna, K. T. (2024). What is CPQ software (Configure Price Quote software)? TechTarget. Preuzeto 2. lipnja 2026. s: <https://www.techtarget.com/searchcustomerexperience/definition/CPQ-software-configure-price-quote-software>
 10. IBM. (2021). IBM Sterling Configure, Price, Quote. Preuzeto 2. lipnja 2026. s: IBM Sterling CPQ
 11. Marti, A., Bastida-Vialcanet, R., & Marimon, F. (2024). A systematic literature review: ESG criteria implementation in the insurance industry. *Intangible Capital*, 20(1), 193–214. Preuzeto 3. lipnja 2026. s: <https://doi.org/10.3926/ic.2426>
 12. Wiener Osiguranje. (2026). Osiguranje za obrtnike i male poduzetnike. Preuzeto 10. lipnja 2026. s: <https://www.wiener.hr/osiguranje-za-obrtnike-i-male-poduzetnike.aspx>

Preliminary communication / Prethodno priopćenje

FINFLUENCERI I FINANCIJSKE PORUKE NA DRUŠTVENIM MREŽAMA: EKSPLORATIVNA ANALIZA SADRŽAJA U HRVATSKOM DIGITALNOM PROSTORU

TONČI SVILOKOS

Sveučilište u Dubrovniku

Ekonomski fakultet

Lapadska obala Nojka Marinovića 7, 20000 Dubrovnik, Hrvatska

tonci.svilokos@unidu.hr

ANTE ZDILAR

Sveučilište u Dubrovniku

Ekonomski fakultet

Lapadska obala Nojka Marinovića 7, 20000 Dubrovnik, Hrvatska

ante.zdilar@unidu.hr

MERI ŠUMAN TOLIĆ

Sveučilište u Dubrovniku

Ekonomski fakultet

Lapadska obala Nojka Marinovića 7, 20000 Dubrovnik, Hrvatska

meri.suman-tolic@unidu.hr

SAŽETAK

Društvene mreže postale su važan izvor financijskih informacija za mlade, pri čemu sve veću ulogu imaju financijski influenceri, odnosno finfluenceri. Njihov sadržaj može pridonijeti popularizaciji financijskih tema i jačanju financijske pismenosti, ali istodobno može sadržavati promotivne, savjetodavne i potencijalno rizične poruke. Cilj rada je utvrditi koje financijske teme dominiraju u objavama finfluencera na društvenim mrežama te u kojoj su mjeri te objave edukativne, savjetodavne, promotivne i potencijalno rizične za financijsko ponašanje mladih. Empirijski dio rada temelji se na eksplorativnoj analizi sadržaja 38 javno dostupnih objava na hrvatskom jeziku s TikToka, platforme YouTube Shorts i Instagrama. Rezultati pokazuju da u analiziranom uzorku dominiraju teme ulaganja, poslovnih financija, osobnih financija i štednje. Većina objava ima edukativni karakter, ali su često prisutni i savjetodavni te promotivni elementi, dok se rizici eksplicitno spominju u manjem dijelu objava. Nalazi upućuju na potrebu jačanja digitalne financijske pismenosti mladih.

KLJUČNE RIJEČI: finfluenceri, digitalna financijska pismenost, društvene mreže, mladi, analiza sadržaja

1. UVOD

Društvene mreže posljednjih su godina postale važan izvor informiranja o financijama, osobito među mladima. Financijske teme koje su se ranije uglavnom povezivale s formalnim obrazovanjem, financijskim savjetnicima ili specijaliziranim medijima danas se sve češće pojavljuju u kratkim videoformatima na TikToku, Instagramu i YouTubeu. U takvom okruženju mladi mogu vrlo brzo doći do sadržaja o štednji, budžetiranju, ulaganju, kriptoomovini, kreditima, porezima, pasivnom prihodu ili tradingu. Takva dostupnost može imati pozitivnu ulogu jer financijske teme čini razumljivijima i bližima svakodnevnom jeziku mladih. Istodobno, isti kanali mogu prenositi pojednostavljene, promotivne ili potencijalno rizične poruke koje mlade korisnike mogu potaknuti na financijske odluke bez dovoljno razumijevanja rizika.

Važnost ove teme posebno dolazi do izražaja u kontekstu financijske i digitalne financijske pismenosti. OECD financijsku pismenost promatra kao kombinaciju financijske svijesti, znanja, vještina, stavova i ponašanja potrebnih za donošenje dobrih financijskih odluka i postizanje financijskog blagostanja (OECD/INFE, 2023). Digitalno okruženje dodatno mijenja način na koji se financijske odluke pripremaju i donose, jer se financijske informacije sve češće primaju kroz aplikacije, internetske platforme, društvene mreže i različite oblike online savjetovanja. Nalazi za Hrvatsku također upućuju na potrebu daljnjeg jačanja financijske i digitalne financijske pismenosti, osobito među mlađim skupinama. Prema istraživanju financijske pismenosti i financijske uključenosti u Hrvatskoj, mlađi od 19 godina ostvaruju najnižu ocjenu financijske pismenosti, dok je prosječna ocjena digitalne financijske pismenosti građana Hrvatske iznosila 49% ukupnog mogućeg rezultata (HNB, HANFA i Ipsos, 2023).

Posebnu ulogu u digitalnom financijskom informiranju imaju financijski influenceri, odnosno finfluenceri. U ovom radu pojam influencer koristi se kao širi pojam, dok se pojam finfluencer odnosi na posebnu skupinu influencera koji stvaraju i dijele sadržaj povezan s osobnim financijama, štednjom, ulaganjem, kriptoomovinom, kreditima, tradingom i drugim financijskim temama. Espeute i Preece (2024) ističu da su finfluenceri postali novi posrednici između financijskih institucija i potrošača, dok International Organization of Securities Commissions (IOSCO, 2025) upozorava da njihov sadržaj može imati edukacijsku vrijednost, ali i stvarati rizike povezane s obmanjujućim informacijama, promocijom složenih ili visokorizičnih proizvoda te nedovoljnim otkrivanjem sukoba interesa. Stoga finfluencere nije primjereno promatrati isključivo kao pozitivan ili negativan fenomen. Njihov učinak ovisi o sadržaju koji objavljuju, načinu na koji komuniciraju rizike, razini transparentnosti i sposobnosti publike da kritički procijeni primljene informacije.

Dosadašnja istraživanja uglavnom se bave financijskom pismenošću mladih, digitalnim financijskim ponašanjem ili općom ulogom društvenih mreža, dok je manje istraženo kakve konkretne financijske poruke stvaraju finfluenceri u manjim nacionalnim digitalnim prostorima poput hrvatskoga.

Cilj je ovog rada utvrditi koje financijske teme dominiraju u objavama finfluencera na društvenim mrežama te u kojoj su mjeri te objave edukativne, savjetodavne, promotivne i potencijalno rizične za financijsko ponašanje mladih.

U skladu s ciljem rada definirana su sljedeća istraživačka pitanja:

- (RQ1) koje se financijske teme najčešće pojavljuju u objavama finfluencera na društvenim mrežama,

- (RQ2) u kojoj mjeri analizirane objave imaju edukativni ili savjetodavni karakter,
- (RQ3) u kojoj mjeri imaju promotivni karakter,
- (RQ4) u kojoj mjeri sadrže potencijalno rizične elemente za financijsko ponašanje mladih,
- (RQ5) koji se mehanizmi utjecaja najčešće koriste.

Empirijski dio rada temelji se na eksplorativnoj analizi sadržaja 38 javno dostupnih objava na hrvatskom jeziku s TikToka, platforme YouTube Shorts i Instagrama. Objave su kodirane prema unaprijed definiranoj kodnoj shemi koja obuhvaća primarnu financijsku temu, edukativni, savjetodavni i promotivni karakter sadržaja, prisutnost poziva na akciju, spominjanje rizika, potencijalno rizične elemente i mehanizme utjecaja. Budući da je riječ o eksplorativnom istraživanju, cilj nije generalizirati nalaze na sve finfluencere ili sve objave na društvenim mrežama, nego prepoznati dominantne obrasce u analiziranom uzorku.

Rad je strukturiran u šest cjelina. Nakon uvoda slijedi pregled literature i ranijih istraživanja o financijskoj i digitalnoj financijskoj pismenosti, finfluencerima i mehanizmima utjecaja na društvenim mrežama. Treće poglavlje opisuje metodologiju istraživanja, kriterije odabira objava i kodnu shemu. U četvrtom poglavlju prikazuju se rezultati istraživanja, a u petom poglavlju dana je njihova interpretacija i usporedba s nalazima ranijih istraživanja. Zaključno poglavlje sažima glavne rezultate, ograničenja istraživanja i preporuke za daljnja istraživanja i financijsku edukaciju mladih.

2. PREGLED LITERATURE I RANIJIH ISTRAŽIVANJA

Financijska pismenost obuhvaća kombinaciju financijskog znanja, stavova i ponašanja potrebnih za donošenje kvalitetnih financijskih odluka. OECD/INFE pristup posebno naglašava međusobnu povezanost tih dimenzija, pri čemu samo poznavanje financijskih pojmova ne znači nužno i odgovorno financijsko ponašanje (Atkinson & Messy, 2012). Lusardi i Mitchell (2014) financijsku pismenost promatraju kao oblik ljudskog kapitala koji utječe na sposobnost pojedinca da planira, štedi, ulaže i upravlja dugom, dok njihova novija istraživanja dodatno naglašavaju njezinu važnost u uvjetima sve složenijih financijskih proizvoda, digitalnih financijskih usluga, inflacije i širenja kriptoomovine (Lusardi & Mitchell, 2023).

Upravo zbog toga financijsku pismenost mladih danas treba promatrati zajedno s digitalnim okruženjem u kojem mladi traže informacije i donose odluke. Europski okvir financijskih kompetencija za djecu i mlade naglašava da se financijske navike razvijaju rano te da mladi trebaju razumjeti osnovne financijske pojmove, šire financijsko okruženje, odnos rizika i prinosa te vanjske utjecaje na financijske odluke, uključujući oglašavanje, društvene mreže, pritisak vršnjaka i influencere (European Union/OECD, 2023). Digitalna financijska pismenost stoga ne uključuje samo sposobnost korištenja aplikacija, kartica, online plaćanja ili investicijskih platformi, nego i sposobnost procjene kvalitete i namjere financijskih informacija koje dolaze iz digitalnih izvora. Mancone et al. (2024) dodatno ističu da financijsko obrazovanje djece i adolescenata može imati pozitivne učinke, ali da su posebno važni iskustveno učenje, prilagodba sadržaja dobi učenika i korištenje digitalnih alata. To upućuje na zaključak da financijska edukacija mladih ne može ostati samo na apstraktnom objašnjavanju pojmova, nego mora uključiti situacije s kojima se mladi stvarno susreću, uključujući društvene mreže.

U tom se prostoru pojavljuju financijski influenceri, odnosno finfluenceri. Oni se najčešće definiraju kao osobe koje na društvenim mrežama stvaraju i dijele sadržaj povezan s osobnim

financijama, štednjom, ulaganjem, kriptoinovinom, tradingom, financijskim planiranjem i drugim financijskim temama (Mölders et al., 2025; IOSCO, 2025). Njihova važnost proizlazi iz činjenice da financijske teme prevode u kratke, vizualne i lako razumljive formate. Time mogu popuniti prostor između formalnog financijskog obrazovanja, tradicionalnog financijskog savjetovanja i potrebe korisnika za brzim, praktičnim objašnjenjima.

Ranija istraživanja pokazuju da finfluenceri često sami sebe vide kao aktere financijske edukacije. Mölders et al. (2025), u istraživanju provedenom na uzorku finfluencera s njemačkog govornog područja, utvrđuju da je 91% ispitanih finfluencera navelo povećanje financijske edukacije pratitelja kao vrlo važan cilj. Isti rad pokazuje da su za uspjeh finfluencera važni kredibilitet, autentičnost i osobnost, što znači da njihova uloga nije samo prijenos informacija, nego i izgradnja odnosa povjerenja s publikom. Međutim, Mölders et al. (2025) istodobno utvrđuju da je 57% ispitanih finfluencera već sudjelovalo u plaćenim partnerstvima s poduzećima, pri čemu su česti oblici suradnje partnerske poveznice i sponzorirane objave. To pokazuje da finfluenceri nisu samo neformalni edukatori, nego i sudionici digitalnog marketinga financijskih proizvoda, usluga i edukacijskih sadržaja.

Ta dvojakost posebno je važna za analizu financijskog sadržaja na društvenim mrežama. Kod klasičnog oglašavanja korisnik uglavnom zna da gleda reklamu. Kod finfluencerskog sadržaja granica je često manje jasna: ista objava može započeti kao edukativno objašnjenje, nastaviti se kao savjet, a završiti pozivom na webinar, preuzimanje vodiča, korištenje aplikacije ili kontaktiranje autora. Espeute i Preece (2024) finfluencere opisuju kao nove posrednike između financijskih institucija i potrošača, pri čemu mogu pružati opće financijske informacije, promovirati proizvode ili usluge, davati smjernice i u pojedinim slučajevima iznositi investicijske preporuke. Time finfluencerski sadržaj postaje hibrid financijske edukacije, savjetovanja, osobnog brendiranja i marketinga.

Način na koji finfluenceri oblikuju financijske poruke također je važan za razumijevanje njihova utjecaja. Hayes i Ben-Shmuel (2024) pokazuju da finfluenceri financijske teme približavaju publici kroz pojednostavljivanje složenih financijskih sadržaja i komunikacijske obrasce prilagođene digitalnim platformama. Zhu i Wang (2025), analizirajući sadržaj finfluencera na YouTubeu i platformi Bilibili, dodatno ističu važnost autentičnosti u njihovoj komunikaciji te identificiraju transparentnost, neposrednost, predstavljanje autora kao „obične“ osobe i iskazivanje osobnog interesa kao važne strategije izgradnje odnosa s publikom. Takvi komunikacijski obrasci mogu povećati razumljivost i privlačnost financijskih tema, ali istodobno otežati jasno razlikovanje edukativnog sadržaja, osobnog iskustva i promotivne poruke.

Važnost takvih poruka posebno dolazi do izražaja kod mlađih korisnika društvenih mreža. Hii i Ong (2026), na uzorku pripadnika generacije Z i milenijalaca, pokazuju da vjerodostojnost finfluencera i kvaliteta financijskih informacija pridonose razvoju parasocijalnog odnosa između autora i pratitelja, koji može biti povezan s prihvatanjem njihovih financijskih obrazaca i namjerom ulaganja. To potvrđuje da pri analizi finfluencerskog sadržaja nije dovoljno promatrati samo financijsku temu objave, nego i način na koji je poruka oblikovana i kojim se mehanizmima nastoji privući povjerenje i potaknuti reakcija publike.

Empirijska istraživanja također pokazuju da u sadržaju finfluencera posebno mjesto zauzimaju investicijske teme. Hasanah et al. (2025) analizirali su sadržaj vodećih finfluencera na TikToku, YouTubeu i Instagramu te utvrdili da dominiraju teme ulaganja, osobito sadržaji o dionicama, kriptoinovini i drugim investicijskim proizvodima. U njihovu preliminarnom istraživanju

među pripadnicima generacije Z kratki videoformati pokazali su se kao preferirani oblik financijskog sadržaja, dok je ulaganje bilo jedna od najprivlačnijih tema. Autori istodobno upozoravaju da većina analiziranih finfluencera nema formalno financijsko obrazovanje ili profesionalne certifikate, što otvara pitanje vjerodostojnosti, kvalitete informacija i mogućnosti širenja rizičnih investicijskih poruka (Hasanah et al., 2025).

Regulatorni izvori dodatno naglašavaju da se financijski sadržaj na društvenim mrežama ne može tretirati kao običan lifestyle sadržaj. IOSCO (2025) ističe da finfluenceri mogu imati pozitivnu ulogu u popularizaciji financijskih tema i širenju pristupa financijskim informacijama, osobito među mladim i novim ulagačima. Ipak, isti izvor upozorava na rizike povezane s neovlaštenim savjetovanjem, financijskim prijevarama, promocijom neprikladnih ili visokorizičnih proizvoda, obmanjujućim sadržajem, nedovoljnim otkrivanjem sukoba interesa i nedostatkom transparentnosti. Posebno su osjetljive objave povezane s kriptoomovinom, forexom, CFD-ovima, trading signalima i plaćenim edukacijskim programima (IOSCO, 2025).

Slične zaključke donose i novija regulatorna izvješća. Financial Industry Regulatory Authority (FINRA, 2025) navodi da društvene mreže mogu povećati pristup investicijskim informacijama i potaknuti interes za financijska tržišta, ali istodobno mogu širiti netočne, pristrane ili nepotpune informacije. Prema istom izvoru, mlađi investitori znatno se češće oslanjaju na društvene mreže za financijske informacije nego starije skupine, a pretjerano oslanjanje na takve izvore može povećati izloženost rizičnim ulaganjima.

Iz prethodnih istraživanja proizlazi da finfluencere nije primjereno promatrati jednostrano. Oni mogu biti koristan kanal za popularizaciju financijskih tema i povećanje interesa mladih za štednju, ulaganje i odgovornije financijsko ponašanje. Istodobno, njihov sadržaj često djeluje u prostoru u kojem se preklapaju edukacija, savjetovanje, promocija i osobni brend. Upravo zato je važno analizirati ne samo o kojim financijskim temama finfluenceri govore, nego i kako ih predstavljaju: imaju li objave edukativni, savjetodavni ili promotivni karakter, spominju li rizike, sadrže li potencijalno rizične elemente i kojim se mehanizmima utjecaja koriste. Na toj se logici temelji empirijska analiza provedena u ovom radu.

3. METODOLOGIJA ISTRAŽIVANJA

Empirijski dio rada temelji se na eksplorativnoj analizi sadržaja javno dostupnih objava na hrvatskom jeziku koje su na društvenim mrežama objavili finfluenceri, financijski edukatori, financijski stručnjaci i financijski orijentirani profili. Analiza sadržaja odabrana je zato što omogućuje sustavno razvrstavanje financijskih poruka prema temama, obilježjima sadržaja i potencijalnim rizicima. Cilj nije bio ispitati stavove mladih korisnika, nego analizirati kakvom su tipu financijskog sadržaja potencijalno izloženi u digitalnom okruženju.

Jedinica analize bila je pojedinačna javno dostupna objava, odnosno kratki videozapis ili objava usporediva s kratkim videoformatom. Analizirane su objave s TikToka, platforme YouTube Shorts i Instagrama. Promatrano razdoblje objava bilo je od 1. studenoga 2025. do 1. svibnja 2026., dok je prikupljanje podataka provedeno tijekom svibnja 2026. Uzorak je oblikovan kao namjerni eksplorativni uzorak. Uključene su objave koje su bile javno dostupne, objavljene u promatranom razdoblju, povezane s financijskom temom i relevantne za područja poput osobnih financija, ulaganja, štednje, budžetiranja, kriptoomovine, tradinga, kredita, poreza, mirovine, potrošnje, digitalnog novca ili poslovnih financija. Iz analize su isključene objave

bez jasne financijske teme, objave izvan promatranog razdoblja, duplikati te sadržaji koji nisu pripadali hrvatskom digitalnom prostoru.

Konačni uzorak obuhvatio je 38 objava: 13 s TikToka, 13 s platforme YouTube Shorts i 12 s Instagrama. Broj objava nije određen kao statistički reprezentativan uzorak svih financijskih objava na društvenim mrežama, nego kao razuman opseg za eksplorativnu analizu. Pri oblikovanju uzorka nastojalo se obuhvatiti različite platforme, autore, vrste izvora i financijske teme.

Za svaku objavu evidentirani su osnovni podaci: platforma, naziv profila ili kanala, ime influencera, datum objave, poveznica na objavu i dostupni pokazatelji angažmana. Kodiranje je provedeno prema unaprijed definiranoj kodnoj shemi. Kodna shema oblikovana je kombinacijom deduktivnog i induktivnog pristupa, u skladu s pristupima kvalitativnoj analizi sadržaja (Hsieh & Shannon, 2005; Krippendorff, 2018). Polazne kategorije izvedene su iz istraživačkih pitanja te prethodne literature i regulatornih izvješća o digitalnoj financijskoj pismenosti, finfluencerima i rizicima financijske komunikacije na društvenim mrežama (Espeute & Preece, 2024; IOSCO, 2025; Mölders et al., 2025; OECD/INFE, 2023), dok su pojedine kategorije dodatno prilagođene tijekom početnog pregleda analiziranih objava.

Kodna shema je obuhvatila primarnu financijsku temu, vrstu izvora, edukativni, savjetodavni i promotivni karakter objave, prisutnost poziva na akciju, spominjanje rizika, postojanje potencijalno rizičnih elemenata, razinu rizika te mehanizme utjecaja, uključujući pojednostavljivanje financijske odluke, autoritet influencera, osobno iskustvo, FOMO (strah od propuštanja prilike), socijalni dokaz, hitnost djelovanja i obećanje brze zarade. Pojedine kategorije nisu bile međusobno isključive. Primjerice, ista objava mogla je istodobno imati edukativni i promotivni karakter ako objašnjava financijski pojam, ali istodobno upućuje korisnika na webinar, aplikaciju, edukaciju, uslugu ili drugi oblik daljnjeg angažmana. Nakon kodiranja provedena je deskriptivna analiza, a rezultati su prikazani kroz broj i udio objava prema platformi, dominantnoj financijskoj temi, karakteru sadržaja, prisutnosti rizičnih elemenata i mehanizmima utjecaja. S obzirom na namjerni i eksplorativni karakter uzorka, rezultati se ne interpretiraju kao reprezentativni pokazatelji ukupnog sadržaja na društvenim mrežama, nego kao indikativni nalazi koji omogućuju prepoznavanje dominantnih obrazaca u analiziranom uzorku.

4. REZULTATI

Analizirani uzorak obuhvaća 38 javno dostupnih objava na hrvatskom jeziku. Uzorak je relativno ravnomjerno raspoređen između triju platformi: TikTok i YouTube Shorts zastupljeni su s po 13 objava, odnosno s po 34,2% uzorka, dok Instagram čini 12 objava, odnosno 31,6% uzorka. Uz platformu je evidentiran i profil odnosno kanal s kojeg je pojedina objava preuzeta, pri čemu je ukupno obuhvaćeno 16 različitih javno dostupnih profila/kanala. Takva struktura omogućuje osnovni uvid u financijski sadržaj na više platformi i kroz različite izvore, ali bez ambicije donošenja reprezentativnih zaključaka o ukupnom sadržaju na pojedinoj društvenoj mreži.

Tablica 1. Struktura uzorka prema platformi


Platforma	Broj objava	Udio	Broj različitih profila/kanala	Raspon broja objava po profilu/kanalu
TikTok	13	34,2%	5	2–3
YouTube Shorts	13	34,2%	7	1–3
Instagram Reels/objava	12	31,6%	4	3
Ukupno	38	100,0%	16	1–3

Izvor: Obrada autora prema kodnoj shemi istraživanja

U analizirani uzorak uključeno je ukupno 16 različitih javno dostupnih profila odnosno kanala. Pri odabiru profila primijenjeni su kriteriji prema kojima je profil trebao imati najmanje 2.000 pratitelja na barem jednoj od promatranih društvenih mreža, redovito objavljivati sadržaj povezan s financijskim temama te ostvarivati vidljivu interakciju s publikom. Na taj se način nastojalo obuhvatiti autore koji imaju određeni doseg i kontinuitet prisutnosti u hrvatskom digitalnom prostoru te čije financijske poruke potencijalno mogu dosegnuti širu publiku. Pojedini profil zastupljen je s najviše tri objave kako bi se smanjila mogućnost da sadržaj jednog autora nerazmjerno utječe na rezultate analize. Konkretni nazivi profila i autora nisu navedeni jer predmet istraživanja nije evaluacija pojedinačnih finfluencera, nego analiza obilježja financijskih poruka i komunikacijskih obrazaca u njihovim objavama.

Najzastupljenija tema u analiziranim objavama je ulaganje, koje se pojavljuje kao primarna tema u 9 objava, odnosno 23,7% uzorka. Nakon toga slijede poslovne financije sa 15,8%, osobne financije i štednja s po 10,5%, dok su kriptoomovina, budžetiranje, kredit i trading zastupljeni u manjem broju objava.


Prikaz 1. Dominantne financijske teme u analiziranim objavama



Izvor: Obrada autora prema kodnoj shemi istraživanja

Analiza karaktera objava pokazuje da sve analizirane objave imaju barem djelomično edukativni karakter. Savjetodavni karakter prisutan je u 36 od 38 objava, odnosno 94,7% uzorka, dok je promotivni element prisutan u 23 objave, odnosno u 60,5% uzorka. Poziv na akciju zabilježen je u 24 objave, odnosno 63,2% uzorka.

Prikaz 2. Edukativni, savjetodavni, promotivni i rizični elementi objava




Izvor: Obrada autora prema kodnoj shemi istraživanja

Rizici se izravno spominju u 11 objava, odnosno u 28,9% uzorka, dok su potencijalno rizični elementi prepoznati u 18 objava, odnosno u 47,4% uzorka. Većina objava procijenjena je kao niskorizična, ali 34,2% objava ima srednju, a 10,5% visoku razinu rizika. Među evidentiranim potencijalno rizičnim elementima pojavljuju se pojednostavljeno prikazivanje složenih financijskih odluka, nedovoljno isticanje mogućih gubitaka ili ograničenja te kombiniranje edukativnih, savjetodavnih i promotivnih poruka unutar iste objave.

U analiziranim objavama prepoznato je više mehanizama utjecaja. Najčešći mehanizmi utjecaja u analiziranim objavama su pojednostavljivanje financijske odluke i oslanjanje na autoritet osobe koja komunicira sadržaj. Pojednostavljivanje je prepoznato u gotovo svim objavama, dok je autoritet influencerica prisutan u 36 od 38 objava. Hitnost djelovanja pojavljuje se u 31,6% objava, osobno iskustvo kao dokaz u 28,9%, FOMO u 18,4%, socijalni dokaz u 15,8%, a obećanje brze zarade u 13,2% objava.

Prikaz 3. Mehanizmi utjecaja u analiziranim objavama



Izvor: Obrada autora prema kodnoj shemi istraživanja

Rezultati pokazuju da analizirani financijski sadržaj na društvenim mrežama najčešće kombinira edukativne, savjetodavne i promotivne elemente. Iako je edukativni karakter prisutan u svim analiziranim objavama, velik broj objava istodobno sadrži savjetodavne poruke,

pozive na akciju ili promotivne elemente. Rizici se izravno spominju u manjem dijelu objava, dok su potencijalno rizični elementi prepoznati u gotovo polovici analiziranog uzorka.

5. RASPRAVA

Dobiveni rezultati pokazuju da financijski sadržaj na društvenim mrežama u hrvatskom digitalnom prostoru ima izražen edukacijski potencijal, ali istodobno često prelazi u područje savjetovanja, promocije i osobnog brendiranja. Ta je dvojakost važna jer analizirane objave ne djeluju samo kao neutralan prijenos financijskih informacija, nego često korisniku sugeriraju određeno ponašanje ili daljnji oblik angažmana. Stoga se finfluencerski sadržaj ne može promatrati isključivo kao oblik financijske edukacije, nego kao hibrid edukacije, savjetovanja, marketinga i digitalnog utjecaja.

Dominacija ulaganja u analiziranom uzorku u skladu je s nalazima ranijih istraživanja. Hasanah et al. (2025) u analizi sadržaja vodećih finfluencera na TikToku, YouTubeu i Instagramu također utvrđuju da investicijske teme zauzimaju najvažnije mjesto, osobito sadržaji o dionicama, kryptoimovini i drugim investicijskim proizvodima. Sličnost s tim nalazom upućuje na to da se i u hrvatskom digitalnom prostoru finfluencerski sadržaj velikim dijelom oblikuje oko ulaganja, a ne samo oko osnovnih tema financijske pismenosti poput štednje i budžetiranja. To je važno jer ulaganje istodobno ima edukacijski potencijal, ali i zahtijeva višu razinu razumijevanja rizika.

Nalaz da sve analizirane objave imaju barem djelomično edukativni karakter potvrđuje da finfluenceri i financijski orijentirani profili mogu imati pozitivnu ulogu u popularizaciji financijskih tema. Međutim, činjenica da je savjetodavni karakter prisutan u gotovo svim objavama, a promotivni element u više od polovice uzorka, pokazuje da se edukativna funkcija često preklapa s usmjeravanjem korisnika prema određenim aktivnostima, proizvodima, uslugama, edukacijama ili daljnjem praćenju sadržaja. Takav je nalaz u skladu s izvješćem IOSCO-a (2025), koje istodobno prepoznaje edukacijsku vrijednost finfluencera i upozorava na rizike promocije rizičnih proizvoda, sukoba interesa i nedovoljne transparentnosti.

Posebno je važno pitanje komuniciranja rizika. U analiziranom uzorku rizici se izravno spominju u manjem dijelu objava, dok su potencijalno rizični elementi prepoznati u gotovo polovici uzorka. Rizik se pritom ne mora nužno nalaziti u otvoreno pogrešnoj informaciji, nego i u načinu prezentacije financijske odluke. Kada se ulaganje, trading, kryptoimovina ili drugi financijski izbori prikazuju pojednostavljeno, bez dovoljno jasnog objašnjenja mogućih gubitaka, ograničenja ili primjerenosti pojedine odluke za različite korisnike, takav sadržaj može stvoriti pogrešan dojam o jednostavnosti financijskog odlučivanja.

Ovi nalazi mogu se povezati i s upozorenjima FINRA-e (2025), prema kojima društvene mreže mogu povećati dostupnost financijskih informacija i interes za financijska tržišta, ali istodobno mogu širiti netočne, pristrane ili nepotpune informacije. To je osobito važno u kontekstu mladih korisnika, koji se u digitalnom okruženju često susreću s kratkim, vizualno privlačnim i pojednostavljenim financijskim porukama. Upravo zato digitalna financijska pismenost ne bi trebala obuhvatiti samo poznavanje financijskih pojmova, nego i sposobnost procjene izvora, prepoznavanja promotivnih elemenata, razlikovanja opće informacije od financijskog savjeta i razumijevanja rizika.

Mehanizmi utjecaja prepoznati u analiziranim objavama dodatno potvrđuju da se financijski sadržaj na društvenim mrežama oblikuje u skladu s logikom digitalnih platformi. Najčešći mehanizmi nisu agresivna obećanja brze zarade ili luksuzni prikazi životnog stila, nego suptilniji oblici utjecaja: pojednostavljivanje financijske odluke, oslanjanje na autoritet osobe koja komunicira sadržaj, osobno iskustvo, hitnost djelovanja i poziv na daljnju aktivnost. Takvi mehanizmi mogu biti korisni kada financijske teme čine razumljivijima i bližima mladima, ali mogu biti problematični ako korisnik promotivnu ili pojednostavljenu poruku protumači kao nepristran financijski savjet.

U cjelini, rezultati upućuju na potrebu uravnoteženog pristupa finfluencerima. Oni nisu isključivo izvor rizika, ali nisu ni neutralni edukatori. Njihov sadržaj može biti vrijedan dodatak financijskoj edukaciji mladih, osobito kada potiče interes za štednju, budžetiranje, dugoročno ulaganje i oprez prema prijevarama. Istodobno, zbog preklapanja edukacije, savjetovanja, promocije i osobnog brenda, takav sadržaj treba promatrati kritički. Stoga se rezultati ovog rada mogu promatrati kao polazište za daljnja istraživanja koja bi, uz analizu sadržaja, uključila i percepciju mladih korisnika te njihov način razumijevanja financijskih poruka na društvenim mrežama.

6. ZAKLJUČAK

Ovaj rad analizira obilježja financijskog sadržaja na društvenim mrežama u hrvatskom digitalnom prostoru, s naglaskom na objave finfluencera i financijski orijentiranih profila kojima mladi mogu biti izloženi u digitalnom okruženju.

Rezultati eksplorativne analize 38 javno dostupnih objava na hrvatskom jeziku pokazuju da u analiziranom uzorku dominiraju teme ulaganja, poslovnih financija, osobnih financija i štednje. Većina objava ima edukativni karakter, što potvrđuje da finfluenceri mogu imati pozitivnu ulogu u popularizaciji financijskih tema. Istodobno, velik broj objava ima savjetodavni i promotivni karakter, dok se rizici eksplicitno spominju u manjem dijelu analiziranih objava.

Dobiveni nalazi uglavnom su u skladu s prethodnim istraživanjima i regulatornim izvješćima o finfluencerima i digitalnoj financijskoj pismenosti. Slično nalazima Hasanah et al. (2025), i u ovom se radu potvrđuje važnost investicijskih tema u financijskom sadržaju na društvenim mrežama. Nalazi su također usporedivi s upozorenjima IOSCO-a (2025) i FINRA-e (2025), prema kojima društvene mreže mogu povećati dostupnost financijskih informacija, ali istodobno mogu sadržavati promotivne, pojednostavljene ili potencijalno rizične poruke. U skladu s Mölders et al. (2025), rezultati upućuju na dvojak karakter finfluencera, koji se mogu pojavljivati kao neformalni edukatori, ali i kao akteri digitalnog marketinga financijskih proizvoda, usluga ili edukacijskih sadržaja.

Među najčešćim mehanizmima utjecaja izdvajaju se pojednostavljivanje financijskih odluka i oslanjanje na autoritet osobe koja komunicira sadržaj. Takvi mehanizmi mogu financijske teme učiniti razumljivijima i pristupačnijima, ali mogu biti problematični ako korisnici pojednostavljenu ili promotivnu poruku protumače kao nepristran financijski savjet.

Doprinos rada ogleda se u tome što pruža početni uvid u obilježja financijskog sadržaja na društvenim mrežama u hrvatskom digitalnom prostoru. Rad pokazuje da finfluencere treba promatrati uravnoteženo: oni nisu samo izvor rizika, ali nisu ni neutralni edukatori. Njihov sadržaj može biti vrijedan dodatak financijskoj edukaciji mladih, ali samo ako se promatra

kritički i ako se mladi osposobljavaju za razlikovanje edukativne informacije, osobnog iskustva, promocije i financijskog savjeta.

Istraživanje ima nekoliko ograničenja. Uzorak je namjerni i eksplorativni, pa se nalazi ne mogu generalizirati na sve finfluencere, sve platforme ili sve objave u hrvatskom digitalnom prostoru. Dodatno, vidljivost sadržaja na društvenim mrežama ovisi o algoritmima, dostupnosti objava i trenutku pretraživanja, dok su pojedini metapodaci, poput broja pregleda ili pratitelja, promjenjivi i nisu uvijek bili dostupni. Kodiranje sadržaja također uključuje određenu razinu istraživačke procjene, osobito kod kategorija poput promotivnog karaktera, savjetodavnosti i razine rizika.

Buduća istraživanja mogla bi proširiti uzorak, uključiti dulje vremensko razdoblje, usporediti različite platforme detaljnije te analizirati percepciju samih mladih korisnika. Posebno bi bilo korisno istražiti u kojoj mjeri mladi razlikuju edukativni financijski sadržaj od promotivnog sadržaja i koliko su sposobni prepoznati rizike povezane s ulaganjima, kriptoinovinom, tradingom i drugim financijskim odlukama. U praktičnom smislu, rezultati upućuju na potrebu jačanja digitalne financijske pismenosti mladih, osobito njihove sposobnosti kritičke procjene financijskih informacija koje primaju putem društvenih mreža.

ZAHVALA

Rad je izrađen u okviru institucijskog istraživačkog projekta FEP – Financial Education Pathways, koji se financira sredstvima Sveučilišta u Dubrovniku i Europske unije – NextGenerationEU.

REFERENCE

1. Atkinson, A., & Messy, F. A. (2012). *Measuring financial literacy: Results of the OECD/International Network on Financial Education (INFE) pilot study* (OECD Working Papers on Finance, Insurance and Private Pensions, No. 15). OECD Publishing. <https://doi.org/10.1787/5k9csfs90fr4-en>
2. Espeute, S., & Preece, R. (2024). *The finfluencer appeal: Investing in the age of social media*. CFA Institute Research and Policy Center. Preuzeto 15. svibnja 2026., s <https://rpc.cfainstitute.org/research/reports/2024/finfluencer-appeal>
3. European Union/OECD. (2023). *Financial competence framework for children and youth in the European Union*. European Union / OECD. <https://doi.org/10.2874/297346>
4. Financial Industry Regulatory Authority. (2025). *Social media-influenced investing*. Preuzeto 13. svibnja 2026., s <https://www.finra.org/rules-guidance/key-topics/fintech/report/social-media-influenced-investing>
5. Hasanah, E. N., Koesrindartoto, D. P., Wiryono, S. K., & Angelica, A. E. (2025). Who deserves to be the finfluencer? *Journal of Open Innovation: Technology, Market, and Complexity*, 11(2), 100553. <https://doi.org/10.1016/j.joitmc.2025.100553>
6. Hayes, A. S., & Ben-Shmuel, A. T. (2024). Under the influence: Financial influencers, economic meaning-making and the financialization of digital life. *Economy and Society*, 53(3), 478–503. <https://doi.org/10.1080/03085147.2024.2381980>
7. Hii, I. S. H., & Ong, Y. X. (2026). Finfluencer: Can financial social media influencers promote desirable financial behaviours? *International Journal of Bank Marketing*, 44(2), 284–312. <https://doi.org/10.1108/IJBM-05-2024-0256>

8. Hsieh, H.-F., & Shannon, S. E. (2005). Three approaches to qualitative content analysis. *Qualitative Health Research*, 15(9), 1277–1288.
<https://doi.org/10.1177/1049732305276687>
9. Hrvatska narodna banka, Hrvatska agencija za nadzor financijskih usluga, & Ipsos. (2023). *Mjerenje financijske pismenosti i financijske uključenosti u Hrvatskoj – 2023* [Prezentacija istraživanja]. Preuzeto 17. svibnja 2026., s
<https://www.hanfa.hr/media/2eukwzku/2023-06-02-hi-final-istrazivanja-ipsos.pdf>
10. International Organization of Securities Commissions. (2025). *Final report: Finfluencers* (FR/08/2025). Preuzeto 14. svibnja 2026., s
<https://www.iosco.org/library/pubdocs/pdf/IOSCOPD795.pdf>
11. Krippendorff, K. (2018). *Content analysis: An introduction to its methodology* (4th ed.). SAGE Publications.
12. Lusardi, A., & Mitchell, O. S. (2014). The economic importance of financial literacy: Theory and evidence. *Journal of Economic Literature*, 52(1), 5-44.
13. Lusardi, A., & Mitchell, O. S. (2023). The importance of financial literacy: Opening a new field. *Journal of Economic Perspectives*, 37(4), 137-154.
14. Mancone, S., Tosti, B., Corrado, S., Spica, G., Zanon, A., & Diotaiuti, P. (2024). Youth, money, and behavior: The impact of financial literacy programs. *Frontiers in Education*, 9, 1397060.
15. Mölders, M., Bock, L., Barrantes, E., & Zülch, H. (2025). Understanding finfluencers: Roles and strategic partnerships in retail investor engagement. *Journal of Business Research*, 198, 115462. <https://doi.org/10.1016/j.jbusres.2025.115462>
16. OECD/INFE. (2023). *OECD/INFE 2023 international survey of adult financial literacy* (OECD Business and Finance Policy Papers, No. 39). OECD Publishing.
<https://doi.org/10.1787/56003a32-en>
17. Zhu, L., & Wang, Y. (2025). Acting real: A cross-cultural investigation of finfluencer strategic authenticity. *International Journal of Advertising*, 44(1), 164–183.
<https://doi.org/10.1080/02650487.2024.2437289>

Preliminary communication / Prethodno priopćenje

INSIGHTS ON AWARENESS OF SUSTAINABLE ENERGY CONSUMPTION

VANESA GUDIĆ

University of Zagreb
Faculty of Organization and Informatics
Pavlinska 2, 42000 Varaždin, Croatia
vgudic22@student.foi.hr

MAJA KUNŠTEK

University of Zagreb
Faculty of Organization and Informatics
Pavlinska 2, 42000 Varaždin, Croatia
mkunstek22@student.foi.hr

NIKOLINA TUMPAK

University of Zagreb
Faculty of Organization and Informatics
Pavlinska 2, 42000 Varaždin, Croatia
ntumpak22@student.foi.hr

MARTINA TOMIČIĆ FURJAN

University of Zagreb
Faculty of Organization and Informatics
Pavlinska 2, 42000 Varaždin, Croatia
martina.tomicic@foi.unizg.hr

ABSTRACT

In modern society, the transition from non-renewable sources to renewable energy is essential for reducing ecological footprints, strengthening the economy, and improving quality of life for present and future generations. This paper gives an overview on sustainable energy policies and literature insights, with the focus on exploring household habits, needs, and potential avenues for energy savings. The research is supported by an exploratory survey, performed on adult citizen in Croatia, examining the extent to which citizens are aware of sustainable consumption practices, and interested in sustainability education, as both being key drivers for fostering responsible, efficient, and environmentally conscious use of energy. The results show that, although the importance of energy sustainability and willingness to change is present, the actual implementation of renewable energy sources in households remains limited.

KEYWORDS: sustainable consumption, renewable energy sources, awareness, practices, sustainability education

1. INTRODUCTION

Sustainable energy consumption is an extremely important factor in protecting the environment, thriving economy and increasing the quality of life of current and future generations. Non-renewable energy sources such as oil, coal, and gas leave a significant ecological footprint in the environment, so the use of renewable electricity sources is gaining increasing importance.

The aim of this research is to examine existing policies, research and current practices of citizens on energy consumption in their households as well as their interest in education on sustainability related to it, in order to shape acceptable household practices that can help in daily activities to promote energy efficiency. Educational programs and workshops are particularly helpful in raising awareness of sustainable consumption among young people, and their implementation from an early age leads to concrete changes for reducing the consumption, creating thereby habits of responsible behavior in energy use (Beširević et al., 2025).

The importance of the research lies in its contribution to the UN Sustainable Development Goals, especially in the fields of quality education, clean and affordable energy, responsible consumption and production, and climate action (European Court of Auditors, 2020). Therefore, it is necessary to strengthen policy, develop national educational programs, and conduct research on consumer knowledge and behavior, especially in the context of new technologies and growing environmental awareness (Grycan, 2020).

The paper consists of six chapters. The first chapter provides an introduction to the topic with key implications related to the topic, while the second chapter explains the research methodology. Third chapter provides an overview of relevant policies in the field of energy sector and energy consumption management, as well as a literature review that covers the topics of renewable and non-renewable energy, sustainable consumption and household energy consumption. The fourth chapter covers the empirical research and the results of it, followed by the discussion and conclusion chapters.

2. METHODOLOGY

The research was conducted in two phases. First, a theoretical background was made through a review of relevant policy documents and existing literature, whereby the theoretical background is not intended to provide a comprehensive overview of all aspects of sustainable energy consumption, but rather to identify the key concepts, challenges, and factors relevant to the present study. This theoretical analysis provided the foundation for identifying the research problem and formulating the research questions.

Based on the theoretical findings, an exploratory survey was conducted to examine sustainable energy consumption practices among Croatian households. The idea for the survey arose due to the unknown of how important sustainable energy consumption is for households, whether households apply certain sustainable practices and how aware they are of the importance of sustainable practices for the betterment of future generations.

Primary data were collected through an online survey created using Google Forms and distributed via social media during May and June 2025. The target population consisted of adult Croatian citizens representing their households, and a total of 105 respondents participated in

the study. A convenience sampling method was used, whereby respondents were selected based on their availability and willingness to participate in the survey.

The survey consisted of two questionnaires. The first examined household energy consumption practices, awareness, and energy-saving behaviors, while the second explored attitudes toward Eco Planner (illustrated in Figure 1.), a proposed educational tool designed to promote sustainable household practices. The solution, in digital and physical format, could provide parents, children and young people and other household members with a practical form of organization, guidance, monitoring, but also entertaining education regarding sustainable practices in the household. Both questionnaires included demographic questions on gender, age, household size, and place of residence.

Figure 1. Eco planer illustration



Source: Authors

Most questions were closed-ended, while several used a Likert scale to measure respondents' attitudes and perceptions. The collected data were analyzed using descriptive statistical methods, primarily frequencies and percentages, to identify trends in sustainable energy consumption practices and attitudes toward educational solutions.

3. THEORETICAL BACKGROUND

The need to reduce energy consumption arises from climate change and security of supply, whereby the responsibility of all stakeholders plays an important role in this process (Kendel & Lazaric, 2015). This chapter provides an overview of policies and trends in the application of renewable and non-renewable energy sources, but also explains what sustainable consumption is, with special emphasis on household energy consumption. Based on the theoretical

3.1. OVERVIEW OF RELEVANT POLICIES

The main document at the European Union level on energy efficiency is the Directive of the European Parliament, which defines the areas in which Europe could and should act in terms of energy efficiency. The directive is important because of its objectives and measures, which are: to reduce energy consumption at the EU level by at least 32.5% by 2030, with an obligation for Member States to save 0.8% of energy annually, public sector buildings must be energy-

efficiently renovated and large companies are required to carry out energy audits (Directive 2012/27/EU, 2012). Furthermore, there is the European Green Deal, which focuses on renewable energy sources and the digital transformation with the aim of transforming the European Union into a modern, resource-efficient and competitive economy (European commission, n.d. -a.). In addition, there is also the package "Ready for 55%" (Council of the European Union) aiming to reduce greenhouse gas emissions in the EU by at least 55% by 2030 and to direct the EU towards achieving climate neutrality by 2050. The EU Renewable Energy Directive (European Commission, n.d. – b.) aims to increase the share of use of renewable energy sources.

From the national perspective, in the Republic of Croatia, it is evident that there are various laws and strategies that promote the application of sustainability and renewable energy sources. Thus, there is the Act on Renewable Energy Sources and High-Efficiency Cogeneration, the main objective of which is to encourage the production and use of electricity from renewable energy sources and high-efficiency cogeneration for the purpose of reducing greenhouse gas emissions, increasing energy independence and transitioning to a more sustainable energy system (Republic of Croatia, n.d.-d). In addition to the aforementioned law, there are also the Electricity Market Act (Republic of Croatia, n.d.-e), the Energy Efficiency Act (Republic of Croatia, n.d.-c), the Environmental Protection Act (Republic of Croatia, n.d.-f) and the Climate Change and Ozone Layer Protection Act (Republic of Croatia, n.d.-c).

The National Development Strategy of the Republic of Croatia until 2030, promotes a digital and green Croatia (Republic of Croatia, n.d.-a). The Energy Development Strategy of the Republic of Croatia until 2030 with a view to 2050, aims to increase domestic production while simultaneously increasing the share of renewable energy sources and reducing the share of fossil fuel-fired thermal power plant. This Integrated National Energy and Climate Plan of the Republic of Croatia from 2021 to 2030, has the main goal to enable a safe and sustainable transition to a low-carbon economy by 2030, using a higher share of renewable energy sources and reducing greenhouse gas emissions and improving energy efficiency. For example, by 2030, efforts are being made to achieve a share of renewable energy sources in gross direct energy consumption in the amount of 42.5% (Republic of Croatia, n.d.-b).

Considering all the aforementioned laws and relevant strategies, energy efficiency and optimization is a priority area in which numerous actions are needed to achieve satisfactory goals. Analyzing the integrated national plan, laws and strategies, it is evident that they all mention similar common goals, namely:

- Increasing the use of renewable energy sources,
- Involvement of citizens and the private sector in the energy transition to the greatest extent possible,
- Initiating and undertaking actions to reduce greenhouse gas emissions,
- Accelerating digital and green transition
- Increasing energy independence and reducing energy poverty and
- Strengthening of national energy sources, specifically from Croatia (like hydrogen).

These are goals for which appropriate actions and steps need to be defined in order to ensure a prosperous energy future for everyone in the ecosystem.

3.2. LITERATURE REVIEW

3.2.1. Renewable and non-renewable energy

In the 21st century, the world is facing the challenge of transitioning from fossil fuels to sustainable energy sources. The main goals are to achieve a sustainable energy balance, avoid negative consequences of global warming and economic problems caused by the reduction and increase in the price of oil and gas reserves (Vojtovic et al., 2018). Electricity is used extensively in industry, but it is an important resource in people's lives as well. The demand for electricity by businesses and residents is increasing, and especially electricity consumption in households is showing a growing trend. The reason for this is the increasing use of high-power intelligent devices and the popularity of home electric vehicles, so energy supply cannot quickly keep up with development needs. The result is an increasing imbalance between energy supply and demand, which on the one hand means an increase in demand during peak hours, while demand decreases during periods of lower consumption, which leads to inefficiency and energy waste.

Non-renewable energy sources, including oil, nuclear energy, coal and natural gas, are easy to store and transport, and they are used for about 90% of the world's energy. However, the reserves of these sources are decreasing, and their use harms the environment. Therefore, today, there is an increasing focus on renewable energy sources – the natural phenomena that will always be present on Earth and will not be used up. Forms of renewable energy sources include water energy, solar radiation, wind, wood, biogas, tides, sea currents and waves and the sea heat. Therefore, also wind power plants, hydroelectric power plants and solar panels are exploited, as they convert one form of renewable energy into another (Ecology, n.d.).

Renewable energy sources are constantly being renewed and can be used without the risk of depletion. One of the most common examples of the use of renewable energy sources is rooftop photovoltaic systems that are integrated into the system to demonstrate the cost-effectiveness of the equipment (Oraedu et al., 2022). Despite their numerous advantages, the share of renewable sources in total energy consumption is around 14%, while solar energy has only 0.8% and wind energy 1% (Grycan, 2020). One of the main reasons for such a small share is the fact that government subsidies and incentives are often needed for renewable sources to be economically viable. However, the number of users who install their own energy sources and sell excess energy to the grid is constantly growing.

Involving youth and the education sector plays a key role in the energy transition with the aim of raising awareness, improving skills and initiating innovations necessary for a sustainable future. Such knowledge and skills enable youth and children to influence and change energy consumption patterns and adopt sustainable practices (United Nations Development Programme). There is still a tendency among respondents towards a willingness to change their daily habits to reduce energy consumption and implement sustainable practices, with 75.24% of them agreeing, but for individuals, i.e. households, there needs to be a real incentive in terms of the benefits that the household achieves (Grycan, 2020).

3.2.2. Sustainable consumption

Kendel and Lazaric (2015) define sustainable consumption as a way of buying and using products or services that takes into account the environmental and social consequences of our choices. Energy is an essential element when it comes to global progress and the daily growth

of the population and economy requires an increasing demand for energy day by day. For this reason, the irresponsible consumption of resources negatively affects the environment, directing the consumption towards following the principles of sustainable energy use (Vojtovic et al., 2018).

According to Oraed et al. (2022) the great consumption of electricity results from population growth in all countries, especially in developing countries. Energy policies play an important role in encouraging consumers to reduce electricity consumption and should take into account the specificities of each sector (industry, households, transport). Analyses show that legislative measures have the strongest impact on reducing electricity consumption in households (approximately two years after their implementation), but without the continuous adoption of new measures, the trend increases again. Comparisons between European countries confirm that approaches to the development of smart grids and energy efficiency are very different, depending on national policies and legislative frameworks (Grycan, 2020).

It is also important to point out that financial incentives for more sustainable energy consumption are most often available to companies, while households are often neglected in this regard (Grycan, 2020). Lu et al. (2018) emphasizes that various financial instruments, such as subsidies and soft loans, exist on the market, but in practice they are mainly targeted at companies (Lu et al., 2018). This means that households have significantly fewer opportunities to obtain financial support for investments in renewable energy sources and energy efficiency, which can slow down the wider implementation of sustainable solutions at the level of individual users. In order to encourage greater citizen involvement, it is necessary to develop policies and programs that will be accessible and adapted to the needs of households, since rising electricity costs are becoming a significant burden for many households (Jukaria et al., 2023). The limited availability of financial incentives for citizens further complicates the transition to more sustainable energy sources, thereby increasing financial pressure on households and slowing down the energy transition process at a broader societal level (Jukaria et al., 2023).

3.2.3. Household energy consumption

Household energy consumption refers to the heating of residential spaces, consumption for hot water, electricity consumption for appliances, cooking and lighting, and energy sources such as gas, wood and others, excluding fuel for transport (Eurostat).

According to Vojtovic et al. (2018), between 2005 and 2015, electricity consumption in EU-28 households decreased by 0.9%. In countries such as Belgium and the United Kingdom, the decrease was even greater. However, in most Member States, an increase in total consumption was recorded, which was highest in Romania (31.0%) and Lithuania (23.0%). In Lithuania, for example, households consume about a third of total energy. Nevertheless, electricity consumption continues to grow despite a general decrease in the consumption of other energy sources. That is why the European Union, through the “Energy 2020” strategy, has highlighted the importance of energy efficiency, with the aim of reducing total consumption by 20% by 2020. The same authors point out that household energy consumption depends on numerous factors, including income, household size and characteristics, heating method, climate and lifestyle. Lack of energy awareness is a major challenge, especially for households with lower incomes. Research also shows that households with higher incomes often do not have a strong motivation to save energy, while for those with lower incomes the situation is reversed and investments in energy-saving devices are of crucial importance to them. In addition, feedback

and the availability of information on savings opportunities also play an important role (Vojtovic et al., 2018).

The trend of increased household consumption is also observed by Brahim (2021) in areas where consumption is increasing due to the use of air conditioners. The author's research objective included more than 500,000 records collected over 350 days, which were used to help develop a machine learning model that would allow for an accurate representation of electricity consumption based on the consumption of household appliances and weather conditions. This model is presented as a “Random Tree” algorithm that would be used to analyze the obtained consumer consumption data and represents a solid foundation for the development of smart systems for monitoring and managing electricity consumption, and would serve households and smart cities in optimizing the use of the most demanding appliances and reducing electricity bills.

Grycan (2020) highlights that the need to educate consumers and reward efficient behavior is increasing every day, taking into account that changes in consumer habits depend not only on the desire to save energy, but also on comfort (simple systems for use, monitoring and saving energy), safety (security in terms of heat or electricity loss) and social factors (the influence of the family/community). However, attitudes and beliefs alone are not enough and that is why educational programs are actually the ones that encourage people to make changes regarding saving and sustainable energy. The final results of the study by Oraedu et al. (2022.) show that policies and measures are the ones that encourage positive attitudes and social norms about sustainable energy consumption in households.

4. SUSTAINABLE ENERGY CONSUMPTION IN CROATIA

Despite the growing importance of sustainable energy consumption, there is limited insight in the existing background into the awareness, practices, and educational needs of households. Therefore, empirical research was conducted to examine current household energy consumption practices and attitudes toward educational solutions in Croatia, as an exploratory study, aimed to give illustration on how it could be performed more widely, for promoting sustainable behavior. For that purpose, the following research questions were defined:

RQ1: Are households aware of the importance of sustainable energy consumption?

RQ2: Do households implement sustainable energy consumption practices?

RQ3: How can households improve the implementation of sustainable practices?

The study included a total of 105 respondents, all of whom participated in both surveys. All respondents fully answered every question in the study. Regarding demographic characteristics, 83.81% of the participants were female, while the remaining 16.19% were male. The largest group of respondents (55.24%) fell into the 18 - 30 age category. Respondents aged 31 - 45 accounted for 28.57% of the total, while those aged 46 - 55 made up 11.43%. Only four respondents were under the age of 18, and one respondent fell into the 56 - 65 age category. In terms of household size, the largest group (46.67%) belonged to households with 3 to 4 members. Households with 5 to 6 members accounted for 30.48% of respondents, while 13.33% belonged to households with 1 to 2 members. Households with more than 6 members accounted for 9.52% of respondents. Regarding place of residence, 81.90% of respondents live in a house, while 18.1% live in an apartment.

The results of the performed survey showed that most citizens are aware of how much energy they consume in their household per month (49.52%), while the rest do not show awareness regarding their monthly energy consumption. This data indicates that a large proportion of citizens are still unaware of their monthly consumption, which reduces the possibility of consuming energy in a sustainable way. Although the majority of respondents, 53.33%, emphasized that sustainable energy consumption is important to them, very few respondents use sustainable forms of energy. The fact that only 9 respondents (8.57%) use solar energy shows that in Croatia, not much attention is still paid to sustainable forms of energy, i.e. people are not inclined to use renewable energy in their households, which is confirmed by the fact that only a modest 4.07% of energy was obtained from solar sources in 2024 in Croatia (TehnoEko, n.d.). Some of the respondents, 41 of them, carry out some activities to reduce energy consumption in their households, but a large part of them, as many as 22, do not carry out any activities, while 42 respondents do not think about it and expressed neither agreement nor disagreement. Therefore, it can be concluded that household members do not consciously think about sustainable practices in their own households. Also, respondents are divided on the inclusion of youth and children in the implementation of sustainable practices. Some households include them in activities that promote sustainability, while others do not.

Regarding the usefulness of the proposed educational tool, the Eco Planner, a large part of the respondents did not express a specific opinion, i.e. they neither agreed nor disagreed with the statement related to the usefulness in monitoring and measuring progress. In this case, a neutral opinion dominates, and the results show such a tendency because people may not yet be in the habit of using such solutions or there is a lack of information about the content, uncertainty about their own motivation, or unclear expectations and benefits related to the use of such tools. The respondents showed that they prefer the digital form, such as a mobile application, which provides them with functionalities such as reminders of a certain sustainable practice, tracking success, and more. The Eco Planner should be visually attractive and practical for children and provide content that is interesting to them, while at the same time useful for developing awareness and responsible behavior.

5. DISCUSSION

The literature review shows that sustainable energy consumption is an important component of achieving European and Croatian energy and climate objectives. While policies increasingly promote energy efficiency and the use of renewable energy sources, households play a crucial role in the success of the energy transition.

Previous studies suggest that household energy consumption is influenced by awareness, motivation, financial factors, and access to information. Education and supportive tools can therefore encourage the adoption of sustainable energy practices, while involving younger household members may contribute to the development of long-term sustainable habits.

The exploratory research conducted in this paper, reveals that, while respondents possess a certain level of awareness regarding the importance of sustainable energy consumption, a corresponding level of engagement has not yet been sufficiently recognized or developed within Croatian households. Although the majority of respondents acknowledge the importance of sustainable energy consumption and are willing to alter their daily habits, very few actually utilize renewable energy sources, such as solar panels, or other solutions that could improve everyday practices. The primary barriers to adoption are high investment costs and issues

regarding the accessibility of information concerning regulations, subsidies, and similar matters. The sole factor motivating citizens to use renewable energy sources is the financial saving realized through long-term use.

An educational tool, such as the proposed Eco Planner, could be useful for the younger population to learn in a fun way how to become a sustainable citizen, but could also provide parents with a way to educate their children. The research found that the respondents have a neutral attitude towards using the described tool, and therefore marketing promotion is very important, which would show that such tools can truly provide certain benefits and that they are not created just for the sake of a nice visual perception, but to increase the individual level of awareness of sustainable consumption.

6. CONCLUSION

This study was aimed on giving insights on sustainable energy consumption, and awareness about it and practices among Croatian households. The theoretical background highlighted the importance of household participation in achieving energy efficiency and sustainability goals, as well as the role of awareness, education, and motivation in encouraging responsible energy consumption. The survey results indicate that respondents are generally aware of the importance of sustainable energy consumption, they implement only some energy-saving practices, but express a positive attitude toward educational tools, such as the proposed Eco Planner, recognizing their potential to support learning, monitoring, and the adoption of sustainable habits within households.

A limitation of the study is the use of a convenience sample of 105 respondents, which limits the generalizability of the findings. Future research could involve a larger and more representative sample, examine differences across demographic groups, and evaluate the effectiveness of educational tools such as Eco Planner in changing household energy consumption behavior over time.

REFERENCES

1. Beširević, N., Broz Boroja, J., & Katalinić, M. (2025). ODGOVORNOM POTROŠNOM DO BOLJE KLIME | Osnovna škola Silvija Strahimira Kranjčevića Zagreb. <https://os-sskranjcevic-zg.skole.hr/odgovornom-potrosnjom-do-bolje-klime/>
2. Brahim, G. B. (2021). Weather Conditions Impact on Electricity Consumption in Smart Homes: Machine Learning Based Prediction Model. 2021 8th International Conference on Electrical and Electronics Engineering (ICEEE), 93–98. <https://doi.org/10.1109/ICEEE52452.2021.9415917>
3. Council of the European Union. Ready for za 55 %. Consilium. Retrieved July 2, 2025, from <https://www.consilium.europa.eu/hr/policies/fit-for-55/>
4. Directive 2012/27/EU of the European Parliament and of the Council of 25 October 2012 on energy efficiency, amending Directives 2009/125/EC and 2010/30/EU and repealing Directives 2004/8/EC and 2006/32/EC Text with EEA relevance (2012). <http://data.europa.eu/eli/dir/2012/27/oj/hrv>
5. Ekologija. Neobnovljivi izvori energije – Ekologija. Retrieved July 2, 2025, from <https://www.ekologija.com.hr/neobnovljivi-izvori-energije/>

6. European Commission (n.d.-a). Energy and the Green Deal. Retrieved July 2, 2025 from https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal/energy-and-green-deal_en
7. European Commission, (n.d.-b). Renewable Energy Directive. Retrieved July 2, 2025, from https://energy.ec.europa.eu/topics/renewable-energy/renewable-energy-directive-targets-and-rules/renewable-energy-directive_en
8. Sustainable development goals, European Court of Auditors. <http://www.eca.europa.eu/hr/Pages/sdgs.aspx?TermStoreId=8935807f-8495-4a93-a302-f4b76776d8ea&TermSetId=749fcbb6-66e8-4c8b-9b6d-89439a74f5a9&TermId=dc957eaf-7f21-4a20-a661-73cc42feb222>
9. Eurostat. Energy consumption in households. Retrieved July 2, 2025, from https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Energy_consumption_in_households).
10. Grycan, W. (2020). Legislative support for improving sustainable and smart electricity consumption in polish residential sector. *Journal of Cleaner Production*, 266, 121995. <https://doi.org/10.1016/j.jclepro.2020.121995>
11. Jukaria, M., Upadhyay, A., & Kumar, A. (2023). Vector Auto-Regression-Based Predictive model for Smart Meter. 2023 International Conference on Device Intelligence, Computing and Communication Technologies, (DICCT), 396–400. <https://doi.org/10.1109/DICCT56244.2023.10110196>
12. Kendel, A., & Lazaric, N. (2015). The diffusion of smart meters in France: A discussion of the empirical evidence and the implications for smart cities. *Journal of Strategy and*
13. Lu, Q., Yu, H., Leng, Y., Hou, J., & Xie, P. (2018). Research on Model and Algorithm of Smart Electricity Consumption Task Scheduling Optimization in Household. *Chinese Society for Electrical Engineering*, 38(13), 3826–3836.
14. Oraedu, C., Idoko, E. C., Ugwuanyi, C. C., Nwanmuoh, E. E., & Onyishi, I. E. (2022). Does smart meter really stimulate households' sustainable electricity consumption behaviour? An attitudinal-behavioural study. *Energy Efficiency*, 15(4), 21. <https://doi.org/10.1007/s12053-022-10025-0>
15. Republic of Croatia. (n.d.-a). Hrvatska 2030. Retrieved July 2, 2025, from <https://hrvatska2030.hr/>
16. Republic of Croatia. (n.d.-b). National NECP tracker | Nacionalni energetska i klimatski planovi. Retrieved July 5, 2025, from <https://necp.door.hr/>
17. Republic of Croatia. (n.d.-c). Zakon o klimatskim promjenama i zaštiti ozonskog sloja—Zakon.hr. Retrieved July 2, 2025, from <https://www.zakon.hr/z/2435/zakon-o-klimatskim-promjenama-i-zastiti-ozonskog-sloja>
18. Republic of Croatia. (n.d.-d). Zakon o obnovljivim izvorima energije i visokoučinkovitoj kogeneraciji—Zakon.hr. Retrieved July 2, 2025, from <https://www.zakon.hr/z/827/zakon-o-obnovljivim-izvorima-energije-i-visokoucinkovitoj-kogeneraciji>
19. Republic of Croatia. (n.d.-e). Zakon o tržištu električne energije 2019-2021—Zakon.hr. Retrieved July 2, 2025, from <https://www.zakon.hr/z/2983/zakon-o-trzistu-elektricne-energije-2019-2021>
20. Republic of Croatia. (n.d.-f). Zakon o zaštiti okoliša—Zakon.hr. Retrieved July 2, 2025, from <https://www.zakon.hr/z/194/zakon-o-zastiti-okolisa>
21. TehnoEko. (n.d.). Pregled solarnih elektrana u Hrvatskoj: Od kućanstava do velikih igrača. Tehnoeko. Retrieved July 9, 2025, from <https://www.tehnoeko.com.hr/10592>
22. United Nations Development Programme. Green and Renewable Energy Transition for Youth and Education | MPTF Office. Retrieved July 9, 2025, from <http://mptf.undp.org/project/00141030>

23. Vojtovic, S., Stundziene, A., & Kontautiene, R. (2018). The Impact of Socio-Economic Indicators on Sustainable Consumption of Domestic Electricity in Lithuania. *Sustainability*, 10(2), Article 2. <https://doi.org/10.3390/su10020162>

Preliminary communication / Prethodno priopćenje

MARKETINŠKA KOMUNIKACIJA ODABRANIH HOTELSKIH PODUZEĆA NA DRUŠTVENIM MREŽAMA: KOMPARATIVNA ANALIZA FACEBOOKA, INSTAGRAMA I TIKTOKA

LUCIA STARČIĆ

Istrialux d.o.o.
Svetvinčenat 20, 52 342 Svetvinčenat, Hrvatska
lucia.starcic123@gmail.com

JASMINA DLAČIĆ

Sveučilište u Rijeci
Ekonomski fakultet
Ivana Filipovića 4, 51 000 Rijeka, Hrvatska
jasmina.dlacic@efri.uniri.hr

KRISTINA ČRNJAR

Sveučilište u Rijeci
Fakultet za menadžment u turizmu i ugostiteljstvu
Primorska 46, 51 410 Opatija, Hrvatska
kristina.crnjar@fthm.hr

JANA PLIŠKO

University of Ljubljana
School of Economics and Business
Kardeljeva ploščad 17, 1000 Ljubljana, Slovenija
Sveučilište u Rijeci
Ekonomski fakultet
Ivana Filipovića 4, 51 000 Rijeka, Hrvatska
jana.plisko@efri.uniri.hr

SAŽETAK

Društvene mreže postale su važan komunikacijski kanal za hotelska poduzeća, osobito za promociju usluga, interakciju s gostima i poticanje angažmana korisnika. Cilj ovog rada jest analizirati marketinšku komunikaciju na društvenim mrežama odabranih hotelskih poduzeća u Hrvatskoj. Istraživanje se usredotočuje na poduzeća kao što su Valamar Riviera, Plava Laguna i Aminess Hotels & Resorts te njihove aktivnosti na platformama Facebook, Instagram i TikTok. Analiza obuhvaća objavljeni sadržaj, vizualne formate, ton komunikacije i pokazatelje angažmana korisnika. Rezultati ukazuju na razlike u komunikacijskim pristupima i razini angažmana na promatranim platformama. Nalazi istraživanja također upućuju na to da marketinška komunikacija putem društvenih mreža može imati širu ulogu u oblikovanju imidža hotelskih poduzeća među različitim skupinama korisnika kao što su potencijalni gosti i budući zaposlenici.

KLJUČNE RIJEČI: društvene mreže, marketinška komunikacija, hotelska industrija, turizam, angažman korisnika, zaposlenici

1. UVOD

U današnje vrijeme suvremena marketinška komunikacija temelji se na komunikacijskim kanalima koji omogućuju jednostavnu, brzu i učinkovitu komunikaciju poduzeća s postojećim i potencijalnim kupcima (Pascucci, Savelli i Gistri, 2023). Prema tome, društvene mreže postaju glavni alat u komunikaciji s ciljanom publikom, a posebno kod poduzeća u turističkom sektoru (Gohil, 2015). Prema podacima Državnog zavoda za statistiku (2025), turizam u Hrvatskoj predstavlja vodeću gospodarsku granu, s udjelom u BDP-u od 11,32%. Isto tako, prihodi hotela u Hrvatskoj u kontinuiranom su rastu, a 2025. godine procjena prihoda iznosila je 528 milijuna američkih dolara, te se predviđa daljnji rast do 2030. godine (Statista, 2025a). S obzirom na iznesenu važnost turizma, ali i hotelske djelatnosti, važno je uključiti društvene mreže kao kanal komunikacije hotelskih poduzeća s gostima i potencijalnim zaposlenicima kao jednim od značajnijih ciljno-interesnih skupina (Anđelić i Grmuša, 2017). Prethodna istraživanja pokazuju da prisutnost turističkih poduzeća na društvenim mrežama utječe na angažman korisnika (Li, Teng i Chen, 2020; Zeng i Gerritsen, 2014), no u manjoj mjeri se pojavljuju usporedne analize koje daju uvid u hotelska poduzeća u Hrvatskoj i njihovu prisutnost na društvenim mrežama, kao i angažman njihovih korisnika.

Komunikacija hotelskih poduzeća kroz društvene mreže predstavlja i vid javne komunikacije koja nije vidljiva samo gostima već i sadašnjim i potencijalnim zaposlenicima kreirajući tako svoj organizacijski imidž i imidž poželjnoga poslodavca. Istraživanja su pokazala da upravljanje markom poslodavca pozitivno utječe na imidž i reputaciju organizacije. Ukoliko se imidž organizacije percipira kao pozitivan, to doprinosi većoj privlačnosti poslodavca i većoj namjeri budućih zaposlenika da se prijave za posao. Pri tome važnu ulogu ima sveukupna dostupnost informacija koje poduzeće plasira putem društvenih mreža (Sivertzen i sur., 2013; Thang i Trang, 2024). Iako je marketinška komunikacija hotelskoga poduzeća putem društvenih mreža primarno usmjerena prema gostima, ona indirektno utječe i na imidž poduzeća kao poželjnoga poslodavca te ima širu implikaciju iz perspektive upravljanja ljudskim potencijalima.

Stoga, aktivnija prisutnost hotelskih poduzeća na društvenim mrežama trebala bi rezultirati i višom razinom angažmana njihove publike, pa se u skladu s tim postavlja istraživačko pitanje: **IP: Kako se odabrana hotelska poduzeća u Hrvatskoj razlikuju u marketinškoj komunikaciji na društvenim mrežama s obzirom na sadržajne teme, vizualne formate, komunikacijski ton i angažman korisnika.**

Glede na navedeno, svrha rada je omogućiti dublji uvid u aktivnosti marketinške komunikacije putem društvenih mreža odabranih hotelskih poduzeća u Hrvatskoj. Cilj rada je analizirati objave i sadržaj istih na društvenim mrežama kod odabranih hrvatskih hotelskih poduzeća. Odabrana hotelska poduzeća za analizu Valamar, Aminess i Plava Laguna prepoznata su kao značajnija u turizmu (Kovačević, 2025; Harča, 2024), te se ističu među najpoželjnijim poslodavcima u turizmu i ugostiteljstvu (MojPosao, 2025) i aktivna su na društvenim mrežama.

Rad doprinosi razumijevanju uloge društvenih mreža u komunikaciji s ciljno-interesnim skupinama, posebice potencijalnim gostima i zaposlenicima hotelskih poduzeća. Također,

doprinosi i razumijevanju poticanja angažmana korisnika društvenih mreža kroz različite vrste promocijskih aktivnosti na istima.

2. KOMUNIKACIJA NA DRUŠTVENIM MREŽAMA

2.1. NAČINI KOMUNIKACIJE NA ODABRANIM DRUŠTVENIM MREŽAMA

Društvene mreže postale su ključni kanal za svakodnevnu komunikaciju, kako na privatnoj, tako i na poslovnoj razini. S obzirom na vrstu sadržaja na društvenim mrežama, kao što je informativni, zabavni ili kontekstualni sadržaj, poduzeća mogu potaknuti različite oblike angažmana korisnika (Krowinska i Dineva, 2025). Iako se stalno pojavljuju novi oblici tih mreža, samo nekoliko njih uspijeva zadržati vrh popularnosti među korisnicima (Arbona, n.d.), a samo njih nekoliko igra važnu ulogu u oblikovanju ponašanja kupaca i trendova u digitalnom svijetu (Israel, 2023).

Facebook je jedan od glavnih kanala komunikacije za korisnike koji žele pratiti informacije o osobama iz svoje mreže te već godinama zadržava status najposjećenije društvene mreže (Bright, Kleiser i Landreth Grau, 2015). Velik dio korisnika posjećuje ga svakodnevno, a najaktivniju publiku prema podacima iz 2025. godine čine osobe u dobi od 25 do 34 godine (32%) (Statista, 2025b). U komunikaciji s korisnicima, mnoga poduzeća na Facebooku koriste prijateljski i neformalan ton kako bi potaknula osjećaj bliskosti i zajedništva, često uz emotikone, humor i vizualni sadržaj poput fotografija i videa (Pereira Correia i sur., 2014).

Iako Facebook zadržava vodeću poziciju, Instagram se ističe kao jedna od najraširenijih društvenih mreža i važan kanal za oglašavanje, osobito među mlađom populacijom (Carta i sur., 2020). Prema podacima iz 2025. godine, najaktivniji korisnici su u dobi od 25 do 34 godine (34%) (Statista, 2026a), zbog čega je Instagram posebno pogodan za poduzeća koja ciljaju mlađu publiku putem oglasa ili suradnje s *influencerima*. Komunikacija na Instagramu uglavnom je prijateljska i opuštena, a temelji se na vizualnom sadržaju poput fotografija i kratkih videozapisa (Silva, Silva i Rodrigues, 2024).

Nakon Instagrama, TikTok se ističe kao jedna od najpopularnijih i najbrže rastućih društvenih mreža, osobito među mlađom populacijom, s više od milijardu aktivnih korisnika (Statista, 2026b). Platforma se temelji na dijeljenju kratkih, personaliziranih videozapisa koji korisnicima pružaju zabavu, povezivanje i razbibrigu (Schellewald, 2023). Prema podacima iz 2025. godine, najzastupljeniji su korisnici u dobi od 25 do 34 godine (41,6%), što TikTok čini posebno atraktivnim za poduzeća usmjerena na mlađu publiku (Statista, 2026b). Komunikacija na TikToku je opuštena, zabavna i neformalna, s naglaskom na dinamičnost, jer korisnici uživaju u neprekidnom pregledavanju kratkih videozapisa (Barta i sur., 2023).

2.2. VAŽNOST MARKETINGA DRUŠTVENIH MREŽA ZA PODUZEĆA U TURIZMU

Društvene mreže imaju ključnu ulogu u turizmu, posebice se ističu prilikom pretraživanja informacija, promocije destinacija i interakcije s kupcima, ali i omogućavaju kupcima lakšu odluku o kupnji (Zeng i Gerritsen, 2014) te imaju pozitivan utjecaj na izgradnju imidža hotelskih poduzeća (Curlin, Kamenjarska i Pejić Bach, 2022). Također, društvene mreže pružaju mogućnost izravne komunikacije s kupcima i dijeljenja sadržaja koji potiče rezervacije i jača emocionalnu povezanost gostiju s destinacijom (Madžar, Šantić i Čečura, 2022). Upravo

kroz takvu povezanost postižu se ključni ciljevi marketinga na društvenim mrežama koji uključuju povećanje prodaje, jačanje prepoznatljivosti marke, informiranje kupaca, podršku kupcima, te istraživanje tržišta (Paliaga i Mihovilović, 2016).

S obzirom na njihovu važnost, turistička poduzeća služe se društvenim mrežama kako bi unutar promocijskih strategija povećala svoju prisutnost, ali i potaknula angažman i povjerenje korisnika (Hvass i Munar, 2012). Angažman na društvenim mrežama poboljšava korisničko iskustvo te se može promatrati kao reakcija korisnika na objavu. Torbarina, Jelenc i Brkljačić (2020) ističu da angažman kao takav može zahtijevati različit napor korisnika, pa sviđanje objave predstavlja nižu razinu angažmana, dok komentiranje objave zahtijeva višu razinu jer je potrebno razmišljati o poruci koja se šalje. Također, angažman je ključan za izgradnju odnosa s pratiteljima i zagovornicima marke te se smatra jednim od glavnih pokazatelja uspješnosti komunikacije poduzeća (Pradhan, Kishore i Gokhale, 2023). Prema Veloso, Ieva i Gómez-Suárez (2024), vrsta sadržaja koji se objavljuje na društvenim mrežama i način na koji hotelska poduzeća odgovaraju na komentare korisnika mogu utjecati na njihov angažman, namjeru rezervacije i imidž hotela.

Prijašnja istraživanja pokazala su da poduzeća u turizmu koja angažiraju svoje korisnike putem društvenih mreža potiču ih da troše više, ostvaruju više rezervacija te primaju više preporuka od svojih pratitelja (Seth, 2012). Uz to, korisnici koji su aktivni na društvenim mrežama razvijaju osjećaj pripadnosti marki i češće dijele informacije o destinaciji (Li, Teng i Chen, 2020). Poduzeća koja efikasno upravljaju kvalitetnim sadržajem mogu bolje informirati svoje goste, koristiti povratne informacije za unaprjeđenje usluga i poticati dugoročni rast destinacija (Appel i sur., 2019). U tom procesu, društvene mreže olakšavaju komunikaciju s gostima, povećavaju kredibilitet usluga, omogućavaju dosezanje teško dostupnih tržišta i smanjuju vrijeme za dopiranje do ciljne publike (Daif i Elsayed, 2019) te stvaraju pozitivan imidž među potencijalnim zaposlenicima. Također, društvene mreže imaju vrlo važnu ulogu u procesu zapošljavanja, budući da ih kandidati koriste prilikom pripreme, a samim time poduzeća koja ih koriste postaju privlačnija kandidatima (Pirić, Masmontet i Martinović, 2018).

3. ANALIZA DRUŠTVENIH MREŽA NA PRIMJERU ODABRANIH HOTELSKIH PODUZEĆA

3.1. METODOLOGIJA ISTRAŽIVANJA

3.1.1. Pregled analiziranih hotelskih poduzeća

Pružatelji turističkih usluga koriste društvene mreže kao ključni kanal za promociju, prikupljanje povratnih informacija i dosezanje novih korisnika (Alkier i Perić, 2021). Sukladno tome, za analizu su odabrana tri hrvatska hotelska poduzeća: Valamar Riviera d.d., Plava Laguna te Aminess Hotels & Resorts, koji spadaju u top 5 najpoželjnijih poslodavaca u turizmu u Hrvatskoj (MojPosao, 2025) te se ubrajaju među najuspješnija hotelska poduzeća i ulažu u razvoj (Kovačević, 2025; Harča, 2024). Zagreb City Hotels nije uzet u analizu zbog portfelja objekata koji se bitno razlikuje od odabranih tri hotelska poduzeća.

Analiza sadržaja provedena je na društvenim mrežama kao što su Facebook, Instagram i TikTok. Analiza sadržaja provedena je u razdoblju od 1. siječnja 2024. do 1. siječnja 2025. godine, dok je analiza TikTok profila obuhvatila samo Valamar i Plavu Lagunu u razdoblju od 1. travnja 2024. do 1. siječnja 2025., budući da Aminess u svojoj promociji sadržaja ne koristi

TikTok. Također, kako je TikTok relativno mlada platforma odabrano razdoblje analize bilo je zajedničko za oba analizirana poduzeća, te stoga kraće od drugih društvenih mreža.

3.1.2. Kriteriji analiziranja društvenih mreža

Analiza je prilagođena specifičnostima turističke industrije i tržišta, a obuhvaća četiri ključna segmenta: tematiku objavljenog sadržaja, vizualni sadržaj, ton komunikacije s ciljanom publikom te metrike angažmana video sadržaja i objava. Podaci su prikupljeni ručnim pregledom i sakupljanjem podataka s javno dostupnih službenih profila navedenih hotelskih poduzeća na pojedinoj platformi, pri čemu su korišteni javno dostupni podaci i objave. Glede na to da neki elementi analize koji upućuju na sam angažman hotelskih poduzeća u društvenim mrežama nisu javno dostupni, isti nisu mogli biti korišteni prilikom analize. U nastavku su objašnjeni kriteriji i definicije istih, koji su korišteni prilikom analize sadržaja uz pojedine kategorije.

Tematika objavljenog sadržaja odnosi se na glavne teme i motive koji se obrađuju u sadržaju objavljenom na društvenim mrežama. U tom pogledu, marketing sadržaja je sve ono što poduzeća stvaraju i dijele kako bi prenesla svoju priču ciljanoj publici, sa svrhom da pridobiju povjerenje kupaca u svoje proizvode i usluge (Patrutiu Baltes, 2015). Vizualni sadržaj obuhvaća nekoliko ključnih elemenata, a to može uključivati fotografije, infografike, pokretne slike u obliku isječaka, kratkih filmova, *gifova*, videozapisa, i ostalih formata (Manic, 2015). Nadalje, ton komunikacije s publikom može biti formalan ili neformalan. Formalan ton karakterizira korporativan način komunikacije, dok neformalan ima osobine ljudskosti i bliskosti (Barcelos, Dantas i Sénécal, 2019).

Metrike angažmana video sadržaja obuhvaćaju nekoliko različitih kriterija prema kojima se analizira sadržaj, a to su redom: ukupan broj objavljenih videa (kao i prosječan mjesečni broj objavljenih videa), ukupan broj pregleda videa (kao i prosječan broj pregleda po videu) te prosječno vrijeme trajanja videa (Copymate, 2024). Nadalje, angažman korisnika se analizira i kroz ukupan i prosječan broj sviđanja, dijeljenja i komentiranja videozapisa (Copymate, 2024). Facebook i Instagram koriste videozapise na *Feedu* i u *Reels* formatu (Newman, 2023), dok TikTok dominira kratkim i dinamičnim videima (Influencer Marketing Hub, 2025). Glede na ograničenu javnu dostupnost nekih video sadržaja poput Instagram *Stories*, isti nisu korišteni u analizi. Kod optimalne duljine trajanja videozapisa, preporučena duljina na društvenim mrežama varira ovisno o platformi: za Facebook je to od 15 sekundi do 2 minute, za Instagram od 15 do 30 sekundi, a za TikTok između 15 i 60 sekundi (Only Social, 2023). Dodatno su uzete u obzir i metrike angažmana objava koje omogućuju bolje razumijevanje reakcija publike na sadržaj koji se objavljuje. One uključuju ukupan broj objava tijekom promatranog razdoblja i prosječan mjesečni broj objava, ukupan broj sviđanja i prosječan broj sviđanja po objavi, ukupan i prosječan broj komentara po objavi te ukupan i prosječan broj dijeljenja po objavi (dKabinet, 2020), odnosno dijele se na pasivne kao što su sviđanje, aktivnije kao što su komentari i aktivne kao što je dijeljenje (Tenenboim, 2022).

3.2. ANALIZA MARKETINŠKE AKTIVNOSTI NA FACEBOOK DRUŠTVENOJ MREŽI

U analizu su uključeni glavni Facebook profili odabranih hotelskih poduzeća, koji su prepoznati po broju pratitelja i aktivnostima usmjerenim na promociju smještajnih kapaciteta i usluga. Točne brojke oznaka „sviđa mi se“ i broja pratitelja nisu dostupne, već su prikazane u Tablici 1. u tisućama radi lakše vizualizacije i usporedbe.

Tablica 1. Rezultati analize marketinške aktivnosti na Facebook društvenoj mreži

Pokazatelj	Valamar	Plava Laguna	Aminess
Broj pratitelja (22. 1. 2025.)	237.000	113.000	177.000
Oznake sviđanja profila (22. 1. 2025.)	234.000	111.000	176.000
Objave koje sadrže fotografije	134	137	148
Videozapisi na <i>Feedu</i>	8	1	3
Videozapisi u <i>Reels</i> formatu	5	34	16
Ukupan broj objavljenih videa (prosječno mjesečno)	13 (1)	35 (3)	19 (2)
Ukupan broj pregleda videa (prosječno po videu)	488.813 (37.601)	566.200 (16.177)	903.700 (47.563)
Sviđanja videa - ukupno (prosječno po videu)	1.113 (85,62)	6.503 (185,80)	3.589 (188,89)
Komentari videa - ukupno (prosječno po videu)	54 (4,15)	291 (8,31)	22 (1,16)
Dijeljenja videa - ukupno (prosječno po videu)	19 (1,46)	318 (9,09)	61 (3,21)
Prosječno vrijeme trajanja videa (sekunde)	33,08	17,26	30,26
Prosječan mjesečni broj objava	11	11	12
Sviđanja objava - ukupno (prosječno po objavi)	51.187 (382)	17.346 (126,61)	53.873 (364)
Komentari objava - ukupno (prosječno po objavi)	1.070 (8)	966 (7,06)	353 (2,39)
Dijeljenja objava - ukupno (prosječno po objavi)	780 (5,82)	352 (2,57)	741 (5)

Izvor: Autori

3.2.1. Tematika objavljenog sadržaja, vizualni sadržaj i ton komunikacije

Objavljeni sadržaj hotelskih poduzeća prvenstveno je usmjeren na predstavljanje hotela, kampova, resorta, vila i smještaja s pogledom na more, prirodnih ljepota destinacija, *wellness* i *spa* centara, bazena, te različitih aktivnosti za djecu i odrasle. Pritom, Valamar dodatno promovira obiteljski zimski odmor i posebne ponude poput *Early Booking*, *Last Minute* i *Black Friday* ponuda, dok Plava Laguna naglašava sportske događaje i program vjernosti *Plava Laguna Club*. Aminess se fokusira na promociju luksuznog smještaja, gastronomiju te posebne ponude za obiteljski i romantični odmor. Također, analizirana poduzeća aktivno kreiraju sadržaj na svojim blogovima, koje potom dijele na Facebooku.

U kontekstu vizualnog sadržaja, analizirana poduzeća koriste iste elemente, pri čemu dominiraju objave koje sadrže visokokvalitetne fotografije, videozapise na *Feedu* i u *Reels* formatu. Pored toga, objavljuju *bannere*, grafičke elemente s privlačnim fotografijama, tekstom i pozivima na akciju za promociju posebnih ponuda i događanja (The Bannermen, n.d.). Zbog jednostavnosti analize *banneri* su uključeni u kategoriju objava koje sadrže fotografije. Videozapisi na *Feedu* rjeđe su korišteni. Rezultati pokazuju da su fotografije i dalje dominantan vizualni format, dok se videozapisi, posebno u *Reels* formatu, rjeđe uvode u marketinšku komunikaciju. U komunikaciji, Valamar i Plava Laguna koriste neformalan ton koji uključuje korištenje *emojija*, aktivno odgovaranje na komentare i poticanje angažmana pratitelja, što

doprinosi jačanju odnosa s ciljnim segmentima. Nasuprot tome, Aminess koristi formalniji pristup komunikaciji te rijetko odgovara na komentare.

3.2.2. Metrike angažmana video sadržaja

Istraživanje je obuhvatilo videozapise na *Feedu* i u *Reels* formatu. U promatranom razdoblju Plava Laguna objavila je najviše videozapisa, a slijede Valamar i Aminess, dok prema kriteriju ukupnog broja pregleda videa Aminess ostvaruje najviše pregleda video sadržaja, zatim slijedi Valamar i Plava Laguna. Aminess ostvaruje najveći broj pregleda videa, što mu omogućuje veću vidljivost i dosezanje šire publike. Navedeni podaci ukazuju na različite obrasce ponašanja i angažmana korisnika, pri čemu je Plava Laguna uspješnija u poticanju aktivnosti sudjelovanja pratitelja putem opcija svidanja, komentiranja i dijeljenja video sadržaja te ima aktivnije angažirane korisnike, dok je Aminess uspješniji u privlačenju većeg broja pasivne publike. U odnosu na njih, Valamar postiže umjeren angažman. S obzirom na preporučeno prosječno trajanje videa na Facebooku, Valamar objavljuje videozapise koji u prosjeku traju 33,08 sekundi, Plava Laguna 17,26 sekundi, a Aminess 30,26 sekundi. Vrijeme trajanja videa je u skladu s preporukama za optimalno trajanje videa na Facebooku, s ciljem zadržavanja pažnje korisnika.

3.2.3. Metrike angažmana objava

Osim video sadržaja, za uspješnu promociju i online prodaju bitne su objave. Prema provedenoj analizi, dolazi se do zaključka kako Valamar i Plava Laguna u prosjeku objavljuju 11 objava mjesečno, dok Aminess 12. Promovirane objave doprinose angažmanu, što je vidljivo kod Valamara i Aminessa koji imaju aktivnije korisnike, što se očituje kroz komentare i dijeljenje sadržaja, dok Plava Laguna ostvaruje dobar organski angažman.

Zaključno, svako poduzeće koristi različite strategije: Valamar se fokusira na veći broj objava koje sadrže kvalitetne fotografije, Plava Laguna na sportske i društvene aktivnosti koje potiču angažman, a Aminess na vizualno privlačne videozapise i luksuzni doživljaj. Sve tri strategije doprinose jačanju vidljivosti, angažmana i lojalnosti korisnika na društvenim mrežama.

3.3. ANALIZA MARKETINŠKE AKTIVNOSTI NA INSTAGRAM DRUŠTVENOJ MREŽI

Analiza marketinške aktivnosti na Instagramu uzima u obzir glavne profile hotelskih poduzeća, a to su redom: Valamar Hotels, Plava Laguna Hotels i Aminess Hotels. Rezultati su prikazani u Tablici 2.

Tablica 2. Rezultati analize marketinške aktivnosti na Instagram društvenoj mreži

Pokazatelj	Valamar	Plava Laguna	Aminess
Ukupan broj objava (26. 2. 2025.)	2.337	1.910	2.406
Broj pratitelja (26. 2. 2025.)	59.300	21.800	25.800
Objave s fotografijama	50	125	133
Videozapisi u <i>Reels</i> formatu	50	38	26
Prosječan mjesečni broj objavljenih videa	4	3	2
Ukupan broj pregleda videa (prosječno po videu)	3.814.547 (76.291)	306.439 (8.064)	327.998 (12.615)

Pokazatelj	Valamar	Plava Laguna	Aminess
Sviđanja videa - ukupno (prosječno po videu)	35.454 (709,08)	6.745 (177,5)	2.639 (101,5)
Komentari videa - ukupno (prosječno po videu)	539 (10,78)	143 (3,76)	24 (0,92)
Dijeljenja videa - ukupno (prosječno po videu)	226 (4,52)	64 (1,68)	24 (0,92)
Prosječno vrijeme trajanja videa (sekunde)	19,46	16,87	25,50
Prosječan mjesečni broj objava	4	10	11
Sviđanja objava - ukupno (prosječno po objavi)	35.792 (715,84)	14.902 (119,22)	9.645 (72,52)
Komentari objava - ukupno (prosječno po objavi)	522 (10,44)	225 (1,8)	74 (0,56)
Dijeljenja objava - ukupno (prosječno po objavi)	104 (2,08)	34 (0,27)	43 (0,32)

Izvor: Autori

3.3.1. Tematika objavljenog sadržaja, vizualni sadržaj i ton komunikacije

Tematski se sadržaj na Instagramu poklapa s onim na Facebooku. Hotelska poduzeća prate trendove u turizmu i objavljuju sadržaj s ciljem privlačenja obitelji, parova, ljubitelja prirode i luksuza kroz posebne ponude i promotivne pakete. Kada je riječ o vizualnom sadržaju, poduzeća objavljuju videozapise u *Reels* formatu i fotografije te koriste Instagram priče, no zbog ograničenog javnog pristupa nije moguće utvrditi količinu objavljenih priča te nisu uključene u analizu. U analiziranom periodu Valamar podjednako koristi fotografije i videozapise u *Reels* formatu, dok Plava Laguna i Aminess objavljuju znatno više fotografija nego videozapisa. U usporedbi s Facebook platformom, zaključuje se kako su poduzeća podložnija objavama u formi fotografija na obje društvene mreže. No, važno je istaknuti da je Instagram platforma koja više preferira video sadržaj zbog njegove dinamičnosti i veće privlačnosti te potencijalno većeg angažmana korisnika. Sva poduzeća koriste neformalan ton, često uz *emojije* i poticanje interakcije postavljanjem pitanja pratiteljima. Pritom Valamar i Plava Laguna aktivno odgovaraju na komentare, dok Aminess, isto kao i na Facebooku, ne odgovara na komentare.

3.3.2. Metrike angažmana video sadržaja

Prilikom analize video sadržaja na Instagramu uočeno je da se na profilima Valamara, Plave Lagune i Aminessa pojavljuju i videa koja nisu njihova, zbog opcije „Dodaj suradnika“. Takve objave nisu uključene u daljnju analizu. Prema kriteriju ukupnog i prosječnog mjesečnog broja objavljenih videa, Valamar je najaktivniji, slijedi Plava Laguna i Aminess. Prema kriteriju ukupnog broja pregleda videa, Valamar ima najveći broj pregleda, zatim slijedi Aminess, a najmanji rezultat bilježi Plava Laguna. Prema kriterijima angažmana video sadržaja na Instagramu, Valamar prednjači u svim metrikama angažmana: po sviđanjima, komentarima i dijeljenju sadržaja, što može upućivati na veću korisničku reakciju na analizirani sadržaj i aktivnije angažirane korisnike, iako se ne mogu isključiti razlike u strukturi publike, plaćenju promociji, karakteristikama sadržaja i algoritamskoj distribuciji. Što se tiče prosječnog vremena trajanja videa na Instagramu, sva tri poduzeća optimiziraju videa prema preporučenim duljinama trajanja (15-30 sekundi).

3.3.3. Metrike angažmana objava

Kao što je i ranije spomenuto, Valamar ima manji broj objava na Instagramu, ali ostvaruje najveći angažman na platformi, dok Plava Laguna i Aminess bilježe znatno manji angažman korisnika, posebno po kriteriju komentiranja i dijeljenja sadržaja. Valamar, s druge strane, uspješno potiče angažman zahvaljujući objavama koje prenose emocije, jasnim pozivima na akciju i sadržaju prilagođenom ciljnoj publici te ima prosječno veći broj kako pasivnog tako i aktivnog angažmana korisnika.

Valamar prednjači u svim segmentima analize Instagram aktivnosti. Njihove objave privlače publiku kroz korištenje video formata te imaju aktivno angažirane korisnike. Nasuprot tome, Plava Laguna i Aminess imaju potencijal za povećanje angažmana korisnika i dosega. Sva poduzeća prate suvremene trendove u turizmu kroz svoje objave.

3.4. ANALIZA MARKETINŠKE AKTIVNOSTI NA TIKTOK DRUŠTVENOJ MREŽI

Valamar i Plava Laguna aktivno koriste ovu platformu, dok Aminess nema otvoren službeni TikTok profil te je isključen iz analize. Daljnja analiza obuhvaća glavne TikTok profile poduzeća. Rezultati analize su prikazani u Tablici 3.

Tablica 3. Rezultati analize marketinške aktivnosti na TikTok društvenoj mreži

Pokazatelj	Valamar	Plava Laguna
Broj pratitelja (7. 4. 2025.)	4.566	2.873
Oznake sviđanja profila (7. 4. 2025.)	28.500	20.100
Ukupan broj objavljenih videa	67	11
Ukupan broj pregleda videa (prosječno po videu)	524.040 (7.821)	1.543.700 (140.336)
Sviđanja videa - ukupno (prosječno po videu)	9.843 (146,91)	2.457 (223,36)
Komentari videa - ukupno (prosječno po videu)	200 (3)	39 (3,55)
Dijeljenja videa - ukupno (prosječno po videu)	783 (11,69)	378 (34,36)
Spremanja videa - ukupno (prosječno po videu)	664 (9,91)	308 (28)
Prosječno vrijeme trajanja videa (sekunde)	oko 15	oko 15

Izvor: Autori

3.4.1. Tematika objavljenog sadržaja, vizualni sadržaj i ton komunikacije

Sadržaj koji poduzeća objavljuju na TikToku nalikuje onome s Instagrama i Facebooka. Valamar na TikToku objavljuje zabavne i dinamične videozapise koji ističu posebnosti destinacija, obiteljske hotele i aktivnosti za djecu, te prirodne atrakcije. Posebnu pažnju posvećuju stvaranju nostalgije za ljetom, primjerice objavama koje broje dane do ljeta. Također promoviraju poznate atrakcije poput Biokovo *Skywalka* i zimske sportove na skijaškoj destinaciji Obertauern. Valamar potiče pratitelje na angažman kroz postavljanje pitanja pratiteljima i prilagođavanje sadržaja mlađoj publici. Plava Laguna fokusira se na prikaz destinacija, prirode i sportskih aktivnosti poput trčanja, te na stvaranje osjećaja ljetne nostalgije

kroz snimke plaža i mora. Posebno ističu obiteljski odmor, prikazujući zajedničke trenutke na plaži i u hotelima. Za razliku od Valamara, Plava Laguna ne kreira novi sadržaj za TikTok, već koristi iste videozapise kao i na drugim društvenim mrežama, što može sugerirati na nedostatak autentičnosti i kreativnosti. U promatranom razdoblju Valamar je objavio znatno više videa u usporedbi s Plavom Lagunom.

Oba poduzeća koriste prijateljski, neformalan i opušten stil komunikacije, prilagođen TikTok publici, koji uključuje upotrebu *emojija*, popularnih TikTok zvukova, neformalnih izraza i skraćenica, poput riječi „fjaka“, „pomalo“, „vibe“, „POV (*Point of View*)“, i sličnih. Aktivno odgovaraju na komentare i prate trendove, što dodatno gradi osjećaj povezanosti s pratiteljima i povećava angažman.

3.4.2. Metrike angažmana video sadržaja

U pogledu angažmana video sadržaja na TikToku, važno je napomenuti da kriterij prosječnog broja objavljenih videa nije izračunat jer nije uzeto u obzir razdoblje od 12 mjeseci (kao što je bio slučaj s Facebookom i Instagramom). Zbog kraćeg vremenskog okvira, podaci nisu relevantni za usporedbu i mogli bi dovesti do pogrešnog tumačenja učestalosti objavljivanja videa. U promatranom periodu, Plava Laguna ostvaruje znatno veći broj pregleda videa, unatoč manjem broju objava. Jedno od mogućih objašnjenja može biti različita razina plaćene promocije, iako ulaganja u oglašavanje nisu bila mjerena u ovom istraživanju radi nedostupnosti podataka. Valamarov najgledaniji video, s ukupno 132.500 pregleda, prikazuje kadrove skijanja na destinaciji Obertauern, dok video Plave Lagune, s najvećim brojem pregleda - ukupno 180.200, prikazuje atraktivne kadrove Umaga i Poreča. Isti je video Plava Laguna objavila i na drugim platformama, gdje bilježi znatno manji angažman, što potvrđuje veću popularnost TikToka za ovakav sadržaj. Prilikom analize metrika angažmana važno je naglasiti da TikTok, za razliku od Facebooka i Instagrama, omogućuje uvid u broj spremanja videozapisa, dok te informacije na ostalim platformama nisu javno dostupne. Prema kriteriju trajanja videa, oba su poduzeća usklađena s preporukama platforme, s prosječnim trajanjem od oko 15 sekundi.

Razlike u ostvarenim rezultatima upućuju na različite promocijske pristupe. Pritom Valamar ima veću bazu pratitelja, dok Plava Laguna ostvaruje povezanost s manjim brojem korisnika, osobito prema broju pregleda videa te ima stoga pasivno angažirane korisnike. Iz analize proizlazi da TikTok korisnici svoj angažman najviše iskazuju putem oznaka svidanja, a tek onda dijeljenjem i spremanjem sadržaja, dok komentiranje ostvaruje najmanji učinak. No bez obzira na navedeno, TikTok predstavlja važnu platformu za izgradnju imidža i visok angažman, posebno među mladom publikom.

Posebno zanimljiva u pogledu zapošljavanja i upravljanja ljudskim potencijalima može biti komunikacija na TikToku koju karakterizira neformalni stil komunikacije hotelskih poduzeća, a primjereno mlađoj populaciji. Unatoč tome što ovim istraživanjem nisu mjereni učinci takve komunikacije na imidž hotelskih poduzeća u pogledu privlačenja ljudskih potencijala, moguće je rezultate istraživanja interpretirati i kao relevantne i iz perspektive upravljanja ljudskim resursima. Prisutnost hotelskih poduzeća na platformama koje intenzivno koristi mlađa populacija može imati širi značaj od same promocije turističke ponude toj skupini potencijalnih gostiju. Predstavljajući ponudu na takvim platformama hotelska poduzeća indirektno oblikuju i svoju prepoznatljivost koja može biti od velikoga značaja u procesu privlačenja budućih zaposlenika. S obzirom na to da su turizam i ugostiteljstvo među najzastupljenijim djelatnostima sezonskog rada mladih u Hrvatskoj (Ministarstvo turizma i sporta Republike

Hrvatske, n.d.), komunikacija putem društvenih mreža, posebice TikTok, može biti usmjerena kako prema potencijalnim gostima tako i prema potencijalnim zaposlenicima predstavljajući poduzeće kao poželjnoga poslodavca.

4. ZAKLJUČAK

Rezultati ovoga istraživanja pokazuju da postoje razlike u pristupima marketinškoj komunikaciji analiziranih hotelskih poduzeća. Iako temeljem dobivenih rezultata nije moguće direktno zaključiti stvarni utjecaj različitih pristupa na privlačenje potencijalnih gostiju i zaposlenika, oni mogu upućivati na važnost promatranja društvenih mreža kao prostora koji utječe na stvaranje više dimenzija identiteta hotelskoga poduzeća. Marketinška komunikacija fokusirana primarno na promociju smještaja, destinacije i ostalih elemenata od značaja za goste istovremeno će formirati i javnu sliku hotelskoga poduzeća. Upravljanje društvenim mrežama ne bi trebalo biti isključivo usmjereno na marketinške ciljeve već bi trebalo sagledavati širu sliku i sudjelovati u sveukupnoj izgradnji marke poslodavca koji će biti privlačan potencijalnim zaposlenicima. U situaciji u kojoj Hrvatska bilježi značajan nedostatak zaposlenika u ugostiteljstvu i turizmu svi kanali komunikacije predstavljaju važnu platformu za njihovo privlačenje.

Također, koristeći različite kanale marketinškog komuniciranja putem društvenih mreža kao i različite pristupe u tonu komunikacije, hotelska poduzeća oblikuju svoj imidž kod ciljno-interesnih skupina. To se odnosi kako na goste i potencijalne goste, tako i na širu javnost i potencijalne zaposlenike, pri čemu neformalna komunikacija koja je pozitivna i prilagođena ciljno-interesnim skupinama, doprinosi pozitivnoj percepciji imidža hotelskih poduzeća. Navedeno istraživanje je indikativno te nije bilo primarno usmjereno na analizu sadržaja društvenih mreža u pogledu privlačenja novih zaposlenika, međutim način na koji hotelska poduzeća komuniciraju na društvenim mrežama oblikuje percepciju različitih dionika, pa tako i onih na tržištu rada. Komunikacija putem društvenih mreža stoga ima širu ulogu. Društvene mreže će predstavljati kanal komunikacije kako za privlačenje budućih gostiju tako i za privlačenje budućih zaposlenika. Način na koji poduzeća komuniciraju s potencijalnim gostima, pristupi koje pritom koriste i autentičnost i vrijednosti koje se iz te komunikacije reflektiraju sudjelovat će u oblikovanju imidža poduzeća kao poslodavca.

Kako se rad usmjerava samo na analizu marketinške komunikacije putem društvenih mreža na tri odabrana hotelska poduzeća u Hrvatskoj, moguće je da bi se analizom na širem uzorku ili kroz fokus na manja hotelska poduzeća ili na specijalizirane vrste hotela npr. *boutique*, *heritage* ili *spa*, dobili drukčiji rezultati glede tona i angažmana korisnika. Stoga se preporuča ponavljanje analize na širem uzorku hotelskih poduzeća u Hrvatskoj ili u regiji. Također, s obzirom na to da u vrijeme analize Aminess nije bio na TikToku te da se vrijeme obuhvata analize za TikTok razlikuje od drugih društvenih mreža preporuča se ponavljanje istraživanja kada Aminess bude prisutan i na toj društvenoj mreži. U samoj analizi korišteni su javno dostupni podaci odabranih hotelskih poduzeća, te vjerujemo da bi se usporedbom podataka dostupnih od strane hotelskih poduzeća uz plaćeno oglašavanje i objave koje se mogu pratiti kroz pozadinske podatke, dobili drukčiji uvidi. Moguće je da su pojedine kategorije u analizi subjektivno određene, pa vjerujemo i da bi korištenje programskih rješenja za analizu sentimenta prilikom marketinške komunikacije ukazalo i na drukčije povezanosti pa se za buduća istraživanja sugerira njihovo korištenje. Također, dodavanjem novih kriterija analize objava na društvenim mrežama mogli bi se dobiti dodatni uvidi kojima bi se mogla poboljšati i bolje usmjeriti marketinška komunikacija hotelskih poduzeća.

ZAHVALA

Ovaj rad financijski je podržan u okviru projekta Sveučilišta u Rijeci ZIP UNIRI-2023-20.

REFERENCE

1. Alkier, R., & Perić, G. (2021). The influence of social networks on the choice of tourism destination: The case of Kvarner. *Bizinfo (Blace)*, 12(2), 215-229. <https://doi.org/10.5937/bizinfo2102215A>
2. Anđelić, V., & Grmuša, T. (2017). Društvene mreže kao medij promocije turističkih odredišta kod mladih. *Media, Culture and Public Relations*, 8(2), 182-193. <https://hrcak.srce.hr/file/294005>
3. Appel, G., Grewal, L., Hadi, R., & Stephen, A. T. (2019). The future of social media in marketing. *Journal of the Academy of Marketing Science*, 48(1), 79-95. <https://doi.org/10.1007/s11747-019-00695-1>
4. Arbona. (n.d.). Zašto je stvaranje kvalitetnog sadržaja ključno za poslovni uspjeh. <https://www.arbona.hr/hr/zasto-je-stvaranje-kvalitetnog-sadrzaja-kljucno-za-poslovni-uspjeh/1115>
5. Barcelos, R. H., Dantas, D. C., & Senecal, S. (2019). The tone of voice of tourism brands on social media: Does it matter?. *Tourism Management*, 74, 173-189. <https://doi.org/10.1016/j.tourman.2019.03.008>
6. Barta, S., Belanche, D., Fernández, A., & Flavián, M. (2023). Influencer marketing on TikTok: The effectiveness of humor and followers' hedonic experience. *Journal of Retailing and Consumer Services*, 70, 1-12. <https://doi.org/10.1016/j.jretconser.2022.103149>
7. Bright, L. F., Kleiser, S., & Landreth Grau, S. (2015). Too much Facebook? An exploratory examination of social media fatigue. *Computers in Human Behavior*, 44(2), 148-155. <https://doi.org/10.1016/j.chb.2014.11.048>
8. Carta, S., Podda, A. S., Reforgiato Recupero, D., Saia, R., & Usai, G. (2020). Popularity prediction of Instagram posts. *Information*, 11(9), 1-17. <https://www.mdpi.com/2078-2489/11/9/453>
9. Copymate. (2024). Video marketing - sve što morate znati. <https://copymate.app/hr/blog/multi/video-marketing-sve-sto-morate-znati/>
10. Ćurlin, T., Kamenjarska, T., & Pejić Bach, M. (2022). Inovativnost u hotelijerstvu: mrežne stranice hrvatskih hotela. *Croatian Regional Development Journal*, 3(1), 90-111. <https://doi.org/10.2478/crdj-2022-0006>
11. Daif, R., & Elsayed, K. (2019). Viral marketing impact on tourism and hospitality industry. *International Journal of Research in Tourism and Hospitality (IJRTH)*, 5(3), 34-41. <http://dx.doi.org/10.20431/2455-0043.0503004>
12. dKabinet. (2020). Analitika na društvenim mrežama: što i kako mjeriti. <https://dkabinet.com/2020/07/07/analitika-na-drustvenim-mrezama/>
13. Državni zavod za statistiku. (2025). Satelitski račun turizma za Republiku Hrvatsku u 2022. <https://podaci.dzs.hr/2024/hr/101483>
14. Gohil, N. (2015). Role and Impact of Social Media in Tourism: A Case Study on the Initiatives of Madhya Pradesh State Tourism. *International Journal of Research in Economics and Social Sciences*, 5(4), 8-15. <https://indianjournals.com/article/ijress-5-4-002>
15. Harča, V. (2024). Aminess podiže plaće i benefite svojim zaposlenicima. *Financije.hr*. <https://financije.hr/aminess-podize-place-i-benefite-svojim-zaposlenicima/>

16. Hvass, K. A., & Munar, A. M. (2012). The takeoff of social media in tourism. *Journal of Vacation Marketing*, 18(2), 93-103. <https://doi.org/10.1177/1356766711435978>
17. Influencer Marketing Hub. (2025). What Is TikTok? - Everything You Need to Know in 2025. <https://influencermarketinghub.com/what-is-tiktok/>
18. Israel, S. (2023). 7 Types of social media and How Each Can Benefit Your Business. <https://blog.hootsuite.com/types-of-social-media/>
19. Kovačević, V. (2025). Najuspješniji hoteli u Hrvatskoj očekuju rast rezervacija u 2025. godini. *Financije.hr*. <https://financije.hr/najuspjesniji-hoteli-u-hrvatskoj-ocekiju-rast-rezervacija-u-2025-godini/>
20. Krowinska, A., & Dineva, D. (2025). The role and forms of social media branded content driving active customer engagement behaviours. *Journal of Marketing Management*, 41(9-10), 1030-1060. <https://doi.org/10.1080/0267257X.2025.2544808>
21. Li, M., Teng, H., & Chen, C. (2020). Unlocking the customer engagement-brand loyalty relationship in tourism social media: The roles of brand attachment and customer trust. *Journal of Hospitality and Tourism Management*, 44, 184-192. <https://doi.org/10.1016/j.jhtm.2020.06.015>
22. Madžar, D., Šantić, M., & Čečura, M. (2022). Mogućnosti brendiranja turističke destinacije na principima storytellinga. *South Eastern European Journal of Communication*, 4(2), 29-39. <https://hrcak.srce.hr/295746>
23. Manic, M. (2015). Marketing engagement through visual content. *Bulletin of the Transilvania University of Braşov*, 8(2), 89-94. https://webbut.unitbv.ro/index.php/Series_V/article/view/4494/3448
24. Ministarstvo turizma i sporta Republike Hrvatske. (n.d.). *Mladi u turizmu*. Ministarstvo turizma i sporta Republike Hrvatske. <https://mints.gov.hr/turizam-za-sve/mladi-u-turizmu/23042>
25. MojPosao. (2025). *Ususret turističkoj sezoni: Ovo su najpoželjniji poslodavci u turizmu i ugostiteljstvu*. <https://mojposao.hr/savjet/a4707e6c-0e42-11f0-af75-02e598dfa48d/ususret-turistickoj-sezoni-ovo-su-najpozelniji-poslodavci-u-turizmu-i-ugostiteljstvu>
26. Newman, J. (2023). Instagram Videos and Reels - What is The Difference & How to Use Them. <https://onlypult.com/blog/what-is-the-difference-between-instagram-videos-and-reels#instagram-videos>
27. Only Social. (2023). How Long Should a Social Media Video Be in 2024? Tips for Every Network. <https://onlysocial.io/how-long-should-a-social-media-video-be-in-2024-tips-for-every-network/>
28. Paliaga, M., & Mihovilović, J. (2016). Marketing putem društvenih mreža. [https://markopaliaga.com/wp-content/uploads/2016/03/Microsoft%20PowerPoint%20-%20Social%20marketing%20network1%20%5BCompatibility%20Mode%5D\(1\).pdf](https://markopaliaga.com/wp-content/uploads/2016/03/Microsoft%20PowerPoint%20-%20Social%20marketing%20network1%20%5BCompatibility%20Mode%5D(1).pdf)
29. Pascucci, F., Savelli, E., & Gistri, G. (2023). How digital technologies reshape marketing: evidence from a qualitative investigation. *Italian Journal of Marketing*, 27-58. <https://doi.org/10.1007/s43039-023-00063-6>
30. Patrutiu Baltes, L. (2015). Content marketing - the fundamental tool of digital marketing. *Bulletin of the Transilvania University of Braşov*, 8(2), 111-118. https://webbut.unitbv.ro/index.php/Series_V/article/view/4497/3451
31. Pereira Correia, P. A., Garcia Medina, I., Fabiola Gonzalez Romo, Z., & Ruth Contreras - Espinosa, S. (2014). The importance of Facebook as an online social networking tool for companies. *International Journal of Accounting and Information Management*, 22(4), 295 - 320. <https://doi.org/10.1108/IJAIM-08-2013-0050>
32. Pirić, V., Masmontet, P., & Martinović, M. (2018). The Relationship between Employer Branding and Social Networks: Analysis from the Perspective of Young

- Graduates. *Journal of Marketing Development and Competitiveness*, 12(2), 30-48.
<https://doi.org/10.33423/jmdc.v12i2.1255>
33. Pradhan, B., Kishore, K., & Gokhale, N. (2023). Social media influencers and consumer engagement: A review and future research agenda. *International Journal of Consumer Studies*, 47(6), 2106-2130. <https://onlinelibrary.wiley.com/doi/abs/10.1111/ijcs.12901>
 34. Schellewald, A. (2023). Understanding the popularity and affordances of TikTok through user experiences. *Media, Culture & Society*, 45(8), 1568-1582.
<https://doi.org/10.1177/01634437221144562>
 35. Seth, G. (2012). Analyzing the Effects of Social Media on the Hospitality Industry. *UNLV Theses, Dissertations, Professional Papers, and Capstones*.
<https://digitalscholarship.unlv.edu/thesesdissertations/1346/>
 36. Silva, C., Silva, S., & Rodrigues, A. (2024). Instagram as a Digital Marketing Tool of a Hotel Brand. *Proceedings of the 7th International Conference on Tourism Research*, 7(1), 390-400. <https://papers.academic-conferences.org/index.php/ictr/article/view/2103/1870>
 37. Sivertzen, A. M., Nilsen, E. R., & Olafsen, A. H. (2013). Employer branding: Employer attractiveness and the use of social media. *Journal of Product & Brand Management*, 22(7), 473-483. <https://doi.org/10.1108/JPBM-09-2013-0393>
 38. Statista. (2025b). We Are Social, & DataReportal, & Meltwater. "Distribution of Facebook users worldwide as of February 2025, by age and gender."
<https://www.statista.com/statistics/376128/facebook-global-user-age-distribution>
 39. Statista. (2025a). Revenue of the hotels industry in Croatia from 2017 to 2030 (in million U.S. dollars). <https://www.statista.com/statistics/1537895/croatia-hotel-market-revenue/>
 40. Statista. (2026a). We Are Social, & DataReportal. Distribution of Instagram users worldwide as of April 2026, by age and gender.
<https://www.statista.com/statistics/248769/age-distribution-of-worldwide-instagram-users/>
 41. Statista. (2026b). We Are Social, & DataReportal, & Manochi. Distribution of TikTok users worldwide as of April 2026, by age and gender.
<https://www.statista.com/statistics/1299771/tiktok-global-user-age-distribution/>
 42. Tenenboim, O. (2022). Comments, shares, or likes: What makes news posts engaging in different ways. *Social Media+ Society*, 8(4), p.20563051221130282.
<https://doi.org/10.1177/20563051221130282>
 43. Thang, N. N., & Trang, P. T. (2024). Employer branding, organization's image and reputation, and intention to apply: The moderating role of the availability of organizational information on social media. *Frontiers in Sociology*, 9, 1256733.
<https://doi.org/10.3389/fsoc.2024.1256733>
 44. The Bannermen. (n.d.). Social Media Ads. <https://thebannermen.com/social-media/>
 45. Torbarina, M., Jelenc, L., & Brkljačić, I. (2020). Increasing consumer engagement on social networks: Social media influencer's followers 'like' to see a face in a post. *Market-Tržište*, 32, 67-81. <https://hrcak.srce.hr/file/360930>
 46. Veloso, M., Ieva, M., & Gómez-Suárez, M. (2024). Social media content strategy in hospitality: The impact of experiential posts and response congruence on engagement, hotel image, and booking intention. *Journal of Hospitality Marketing & Management*, 33(1), 57-77. <https://doi.org/10.1080/19368623.2023.2241041>
 47. Zeng, B., & Gerritsen, R. (2014). What do we know about social media in tourism? A review. *Tourism Management Perspectives*, 10, 27-36.
<https://doi.org/10.1016/j.tmp.2014.01.001>

Preliminary communication / Prethodno priopćenje

ONLINE PRODAJA KAO POKAZATELJ MEĐUNARODNE TRŽIŠNE ORIJENTACIJE HRVATSKIH MIKRO, MALIH I SREDNJIH PODUZEĆA U PRERAĐIVAČKOJ INDUSTRIJI

KLARA ŠILEC

Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinka 2, 42000 Varaždin, Hrvatska
ksilec@foi.hr

ZRINKA LACKOVIĆ VINCEK

Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinka 2, 42000 Varaždin, Hrvatska
zlackovi@foi.unizg.hr

VLADIMIR KOVŠKA

Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinka 2, 42000 Varaždin, Hrvatska
vladimir.kovska@foi.unizg.hr

SAŽETAK

Rad istražuje online prodaju kao potencijalni pokazatelj međunarodne tržišne orijentacije hrvatskih proizvodnih mikro, malih i srednjih poduzeća (MSP). Polazi se od pretpostavke da digitalni prodajni kanali mogu povećati tržišnu vidljivost poduzeća, olakšati pristup inozemnim kupcima i smanjiti dio prepreka povezanih s tradicionalnim oblicima izlaska na strana tržišta. Empirijsko istraživanje provedeno je na uzorku od 87 hrvatskih poduzeća iz odabranih djelatnosti prerađivačke industrije. Podaci su prikupljeni iz javno dostupnih poslovnih baza podataka i službenih internetskih stranica poduzeća, a istraživanje se temelji na strukturiranoj analizi sadržaja javno dostupnih sekundarnih podataka, uz primjenu deskriptivne statistike i hi-kvadrat testa nezavisnosti. Rezultati pokazuju da većina analiziranih poduzeća ima neki oblik online prodaje, no razvijenost elemenata povezanih s međunarodnom tržišnom orijentacijom razlikuje se među promatranim djelatnostima. Utvrđena je statistički značajna povezanost između djelatnosti poduzeća i postojanja online prodaje te između jezične prilagodbe internetske prodavaonice i opcije dostave proizvoda u inozemstvo. S druge strane, povezanost između geografskog doseg dostave i raznolikosti načina plaćanja nije statistički potvrđena. Nalazi upućuju na važnost digitalnih prodajnih kanala u jačanju izvozne i digitalne spremnosti proizvodnih MSP-ova.

KLJUČNE RIJEČI: online prodaja, internacionalizacija, prekogranična online prodaja, međunarodna tržišna orijentacija, mikro, mala i srednja poduzeća, prerađivačka industrija

1. UVOD

Mikro, mala i srednja poduzeća (MSP) predstavljaju važan segment gospodarstva, pri čemu njihova važnost proizlazi iz njihove brojnosti i gospodarskog doprinosa. Organizacija za ekonomsku suradnju i razvoj (OECD) ističe da MSP-ovi čine oko 99 % svih poduzeća u zemljama OECD-a, zapošljavaju približno dvije trećine radnika te stvaraju oko 50 % do 60 % dodane vrijednosti (OECD, n.d.). Stoga su MSP-ovi relevantna skupina za istraživanje digitalnih prodajnih kanala i spremnosti za nastup na inozemnim tržištima. Internacionalizacija poslovanja posebno je važna za hrvatska proizvodna poduzeća zbog ograničene veličine domaćeg tržišta i potrebe za jačanjem izvozne konkurentnosti. Prema privremenim podacima Državnog zavoda za statistiku (2026), ukupan robni izvoz Republike Hrvatske (RH) u 2025. godini iznosio je 25,2 mlrd. EUR, dok je uvoz iznosio 44,8 mlrd. EUR. Vanjskotrgovinski deficit iznosio je 19,6 mlrd. EUR, a pokrivenost uvoza izvozom bila je 56,2 %. Navedeni podaci upućuju na važnost jačanja izvozne sposobnosti i međunarodne tržišne orijentacije hrvatskih poduzeća, osobito proizvodnih MSP-ova.

U kontekstu internacionalizacije malih i srednjih poduzeća sve veću važnost imaju digitalni prodajni kanali. Cassia i Magno (2022) ističu da je digitalizacija važna za internacionalizaciju MSP-ova te da internet može olakšati analizu stranih tržišta, ubrzati ulazak na tržište i podržati odnose s kupcima. Posebno naglašavaju prekograničnu elektroničku trgovinu (engl. *cross-border e-commerce*) kao oblik ulaska na inozemno tržište, pri čemu ga definiraju kao prodaju dobara i usluga inozemnim kupcima putem interneta. Takav pristup posebno je relevantan za MSP-ove jer e-trgovina, među ostalim, može smanjiti dio prepreka povezanih s tradicionalnim oblicima izvoza i omogućiti izravniji pristup stranim kupcima (Cassia & Magno, 2022).

U ovom se radu prekogranična online prodaja (engl. *cross-border online sales*) promatra kao mogući pokazatelj spremnosti hrvatskih proizvodnih MSP-ova za nastup na inozemnim tržištima. Cilj rada je istražiti u kojoj mjeri obilježja online prodaje mogu upućivati na međunarodnu tržišnu orijentaciju hrvatskih proizvodnih MSP-ova te identificirati elemente digitalnih prodajnih kanala povezane sa spremnošću za nastup na inozemnim tržištima. U tu svrhu provedena je strukturirana analiza javno dostupnih obilježja online prodaje na uzorku od 87 poduzeća iz prerađivačke industrije. Istraživanje je usmjereno na odabrane proizvodne djelatnosti povezane s proizvodnjom prehrambenih proizvoda duljeg roka trajanja, proizvoda modne industrije i kozmetičkih proizvoda. Navedene djelatnosti odabrane su jer obuhvaćaju proizvode koji su, zbog svoje trajnosti, manje osjetljivosti na vanjske uvjete i prikladnosti za pakiranje i dostavu, pogodni za online prodaju i potencijalnu distribuciju izvan domaćeg tržišta. Doprinos rada ogleda se u analizi javno vidljivih obilježja online prodaje kao pokazatelja međunarodne tržišne orijentacije proizvodnih MSP-ova. Rad je strukturiran u pet poglavlja. Nakon uvoda, u drugom se poglavlju predstavlja teorijski okvir unutar kojeg se razmatra internacionalizacija malih i srednjih poduzeća u prerađivačkoj industriji te se obrađuje online prodaja odnosno prekogranična online prodaja kao potencijalni pokazatelji međunarodne tržišne orijentacije. U trećem poglavlju prikazana je metodologija istraživanja, uključujući opis uzorka, izvore podataka i istraživačke hipoteze. Četvrto poglavlje donosi rezultate empirijskog istraživanja i njihovu raspravu, dok se u završnom poglavlju iznose zaključci, ograničenja istraživanja i preporuke za buduća istraživanja.

2. TEORIJSKI OKVIR

U ovom poglavlju iznose se teorijska polazišta relevantna za razumijevanje povezanosti internacionalizacije mikro, malih i srednjih poduzeća, obilježja online prodaje i međunarodne tržišne orijentacije. Poglavlje najprije prikazuje osnovna obilježja i izazove internacionalizacije MSP-ova u prerađivačkoj industriji, a zatim razmatra online prodaju kao mogući pokazatelj njihove usmjerenosti prema inozemnim tržištima.

2.1. INTERNACIONALIZACIJA MIKRO, MALIH I SREDNJIH PODUZEĆA U PRERAĐIVAČKOJ INDUSTRIJI

Prema kriterijima Europske unije, MSP-ovima se smatraju poduzeća s manje od 250 zaposlenih, pri čemu se uz broj zaposlenih uzimaju u obzir i financijski kriteriji. Mikro poduzeća imaju manje od 10 zaposlenih te godišnji promet ili ukupnu bilancu do 2 milijuna eura. Mala poduzeća imaju manje od 50 zaposlenih te godišnji promet ili ukupnu bilancu do 10 milijuna eura, dok srednja poduzeća imaju manje od 250 zaposlenih te godišnji promet do 50 milijuna eura ili ukupnu bilancu do 43 milijuna eura (Europska unija, n.d.).

U kontekstu globalizacije izvozna uspješnost postaje sve važnija za mala i srednja poduzeća jer im izvoz omogućuje prodaju proizvoda na inozemnim tržištima i ostvarivanje koristi od ekonomije razmjera (Alegre i sur., 2022). To je osobito važno za proizvodne MSP-ove, koji se zbog ograničene veličine, resursa te proizvodnih i distribucijskih kapaciteta često usmjeravaju na manje tržišne niše (Alegre i sur., 2022). Autori također ističu da se izvoz, u usporedbi s drugim oblicima ulaska na strana tržišta, može ostvariti uz manji angažman resursa, što ga čini posebno relevantnim oblikom internacionalizacije za MSP-ove (Alegre i sur., 2022). Istodobno, internacionalizacija proizvodnih MSP-ova predstavlja izazov zbog ograničenja u pristupu međunarodnim tržištima i sudjelovanju u međunarodnoj trgovini s kojima se često suočavaju (Ho & Nguyen, 2024). Autori također pokazuju da veličina poduzeća ima važnu ulogu u uključivanju u međunarodnu trgovinu, pri čemu je u promatranom razdoblju izvezilo ili uvezilo 2,3 % mikro, 23,7 % malih i 65,4 % srednjih poduzeća u prerađivačkoj industriji (Ho & Nguyen, 2024). Navedeno upućuje na to da manja proizvodna poduzeća teže sudjeluju u međunarodnoj trgovini, zbog čega je relevantno analizirati obilježja koja mogu upućivati na njihovu spremnost za nastup na inozemnim tržištima (Ho & Nguyen, 2024).

Važnost internacionalizacije MSP-ova prepoznata je i na razini Europske unije. U izvješću o strategiji internacionalizacije MSP-ova Europske unije ističe se da je širenje na međunarodna tržišta izvan Europe ključna prilika za rast i jačanje konkurentnosti MSP-ova, dok se izvoz povezuje s gospodarskim rastom, zaposlenošću i uravnoteženom vanjskom trgovinom (Europska komisija, 2025). U istom je izvješću mapiran 251 instrument potpore internacionalizaciji MSP-ova na razini država članica, dok je na razini EU-a identificirano 45 instrumenata povezanih s internacionalizacijom MSP-ova (Europska komisija, 2025). Za Republiku Hrvatsku su pritom identificirana četiri instrumenta potpore internacionalizaciji MSP-ova, što pokazuje da se ova tema razmatra i u nacionalnom okviru, ali u znatno manjem opsegu nego u većim zemljama članicama (Europska komisija, 2025). Potpora internacionalizaciji MSP-ova najčešće je usmjerena na prevladavanje praktičnih prepreka izlasku na strana tržišta, poput pristupa tržišnim informacijama, pronalaska partnera i klijenata, razvoja strategije te osiguravanja financijske i nefinancijske potpore (Europska komisija, 2025). Ti su elementi važni jer internacionalizacija MSP-ova ne ovisi samo o postojanju izvozne namjere, nego i o sposobnosti poduzeća da prepozna tržišne prilike, prilagodi prodajne kanale i uspostavi kontakt s kupcima izvan domaćeg tržišta. U tom smislu digitalni prodajni

kanali mogu imati posebno važnu ulogu jer digitalizacija, točnije platforme za e-trgovinu i digitalni marketinški alati omogućuju MSP-ovima predstavljanje proizvoda međunarodnoj publici bez potrebe za fizičkom prisutnošću na stranom tržištu (Europska komisija, 2025). Aktualnost istraživanja internacionalizacije MSP-ova potvrđuje i sustavni pregled literature Calheiros-Lobo i suradnika (2023), koji obuhvaća razdoblje od 1920. do 2023. godine, uz detaljniju analizu literature u razdoblju od 2014. do 2023. godine. Njihov rad pokazuje da su ključna pitanja istraživanja internacionalizacije MSP-ova povezana s ulaskom na strana tržišta, izvoznom uspješnošću i čimbenicima koji MSP-ovima omogućuju ne samo početak izvoza, nego i dugoročno profitabilno poslovanje na inozemnim tržištima (Calheiros-Lobo i sur., 2023).

S obzirom na navedena ograničenja proizvodnih MSP-ova u sudjelovanju u međunarodnoj trgovini, kao i na važnost izvozne orijentacije za širenje tržišnog dosega i prevladavanje ograničenja domaćeg tržišta, digitalni prodajni kanali mogu se promatrati kao jedan od mogućih načina jačanja njihove međunarodne tržišne prisutnosti. Takvi kanali ne zamjenjuju tradicionalne oblike internacionalizacije, ali mogu povećati vidljivost i dostupnost proizvoda inozemnim kupcima te smanjiti dio prepreka povezanih s fizičkom prisutnošću na stranom tržištu.

2.2. ONLINE PRODAJA KAO POKAZATELJ MEĐUNARODNE TRŽIŠNE ORIJENTACIJE

Prekogranična e-trgovina u literaturi se razmatra kao jedan od oblika internacionalizacije malih i srednjih poduzeća, odnosno kao način ulaska na strana tržišta kojim se mogu smanjiti određene tradicionalne prepreke internacionalizaciji (Pan i sur., 2023). Digitalizacija ima važnu ulogu u razvoju prekogranične e-trgovine MSP-ova jer povećava njihove mogućnosti za inovacije, rast, učinkovitost, konkurentnost i širenje tržišnog dosega (Dallocchio i sur., 2024). Vlastita internetska trgovina povezana je s povećanjem vjerojatnosti prekogranične e-trgovine za 19,3 %, dok je prisutnost na platformama trećih strana, odnosno internetskim tržištima, povezana s povećanjem te vjerojatnosti za 28 % (Dallocchio i sur., 2024). Društvene mreže i praćenje podataka također su statistički značajno povezani s prekograničnom e-trgovinom, pri čemu društvene mreže povećavaju vjerojatnost prekogranične e-trgovine za 6,5%, a praćenje podataka za 6,3 % (Dallocchio i sur., 2024). Prekogranična e-trgovina ne može se promatrati isključivo kao tehnički prodajni kanal, nego i kao mehanizam prilagodbe poslovanja zahtjevima stranih tržišta (Pan i sur., 2023). Rezultati panel-regresije pokazuju da prekogranična e-trgovina ima izravan pozitivan učinak na tržišne inovacije, dok na tehnološke i procesne inovacije djeluje neizravno, putem poduzetničke orijentacije (Pan i sur., 2023). Uključivanje u prekograničnu e-trgovinu stoga može potaknuti MSP-ove na prilagodbu proizvoda, prodajnih aktivnosti i poslovnih procesa potrebama međunarodnih kupaca (Pan i sur., 2023). U talijanskom kontekstu hrana i piće te moda čine 77 % B2C izvoza putem prekogranične e-trgovine, dok se više od 90 % talijanskog B2C izvoza putem e-trgovine ostvaruje preko platformi trećih strana (Cassia & Magno, 2022). Hamad i sur. (2018) istraživali su čimbenike koji utječu na razine prihvatanja e-trgovine na uzorku egipatskih proizvodnih B2B MSP-ova, a rezultati istraživanja pokazali su da veličina poduzeća nema značajan učinak na prihvatanje e-trgovine, dok kao ograničenje istraživanja autori navode izostanak razmatranja utjecaja djelatnosti, kulturoloških obilježja i internacionalizacije (Hamad i sur., 2018).

Važan element razvijenosti prekogranične e-trgovine odnosi se i na dostupnost različitih načina plaćanja, budući da digitalna financijska rješenja povećavaju praktičnost, dostupnost i sigurnost prekograničnih financijskih usluga te omogućuju korištenje kreditnih kartica, e-novčanika,

mobilnih plaćanja i drugih digitalnih oblika plaćanja (Meng i Xiao, 2025). Stoga se raznolikost ponuđenih načina plaćanja u ovom radu promatra kao jedan od pokazatelja prilagođenosti online prodaje zahtjevima međunarodnih kupaca. Strzelecki (2019) pokazuje da se prilagodba internetskih prodavaonica prekograničnoj e-trgovini očituje kroz više obilježja, uključujući međunarodno prepoznatljive načine plaćanja, valutu, mogućnost dostave u inozemstvo, sigurnost internetske stranice te jezičnu i lokacijsku prilagodbu. Iako su u analiziranom uzorku poljskih e-trgovaca elektronički načini plaćanja i sigurnosni elementi bili razvijeni, izostanak jezične i valutne prilagodbe upućuje na ograničenu razinu prilagođenosti stranim kupcima (Strzelecki, 2019). Iako se u predstavljenim istraživanjima uglavnom upotrebljava širi pojam elektroničke trgovine, predmet je ovog istraživanja online prodaja koja se u ovom radu definira kao prodaja proizvoda putem interneta, koja se odvija preko vlastite internetske prodavaonice poduzeća ili posredstvom internetskih tržišta. Za razliku od elektroničke trgovine, koja obuhvaća širi skup elektronički podržanih aktivnosti kupnje i prodaje, online prodaja odnosi se na prodajnu stranu takvih transakcija i ograničena je na prodajne kanale dostupne putem interneta. Online prodaja u ovom se radu promatra kao vidljivi pokazatelj usmjerenosti hrvatskih proizvodnih MSP-ova prema inozemnim tržištima. Pritom se ne pretpostavlja da sama prisutnost online prodaje automatski znači ostvarenu internacionalizaciju, nego da razvijenost digitalnih prodajnih kanala, uključujući vlastitu internetsku prodavaonicu i prisutnost na internetskim tržištima, može upućivati na veću spremnost poduzeća za nastup na međunarodnom tržištu.

Iako navedena istraživanja upućuju na povezanost prekogranične e-trgovine s internacionalizacijom te ističu važnost pojedinih dimenzija prilagodbe za uspješan nastup na stranim tržištima, dosadašnja literatura rijetko istovremeno razmatra utjecaj djelatnosti poduzeća i stupnja internacionalizacije na razvijenost online prodaje, na što upućuju i sami Hamad i sur. (2018) navodeći izostanak tih varijabli kao ograničenje vlastitog istraživanja. Dodatno, većina spomenutih studija provedena je na razvijenim ili digitalno zrelijim tržištima, dok istraživanja koja bi navedene pokazatelje prilagođenosti online prodaje povezala s djelatnošću poduzeća u kontekstu manje digitalno razvijenog tržišta, poput hrvatskog, izostaju.

3. METODOLOGIJA

Empirijski dio rada temelji se na strukturiranoj analizi sadržaja javno dostupnih sekundarnih izvora podataka o hrvatskim mikro, malim i srednjim poduzećima s dostupnom internetskom stranicom iz prerađivačke industrije. Analiza sadržaja odabrana je jer podaci o funkcionalnostima internetskih prodavaonica, poput jezične prilagodbe, mogućnosti prekogranične dostave i geografskog dosega dostave, valute te načina plaćanja nisu dostupni u standardiziranom obliku u postojećim bazama podataka. Stoga su navedena obilježja identificirana pregledom službenih mrežnih stranica i internetskih prodavaonica poduzeća te kodirana kao kategorijske varijable prema unaprijed definiranim kriterijima. Kodiranje je provodila jedna osoba te kako bi se smanjila subjektivnost postupka, primijenjeni su jedinstveni kriteriji kodiranja, a nejasni slučajevi ponovno su provjereni prema istim pravilima. Kodirana obilježja najprije su analizirana primjenom deskriptivne statistike, a za ispitivanje njihove međusobne povezanosti primijenjen je Pearsonov hi-kvadrat test nezavisnosti. Odabir navedenog testa bio je opravdan kategorijskom prirodom analiziranih varijabli i ciljem utvrđivanja razlikuju li se opažene frekvencije od frekvencija koje bi se očekivale u slučaju njihove međusobne nezavisnosti. Uz rezultate testa prikazan je i Cramérov V kao pokazatelj jačine povezanosti. Istraživanje je provedeno u lipnju 2026. godine, pri čemu su analizirani

podaci o poslovanju poduzeća u 2025. godini te aktualni podaci dostupni na njihovim službenim mrežnim stranicama u trenutku provedbe istraživanja.

Uzorak istraživanja čini 87 hrvatskih mikro, malih i srednjih poduzeća s dostupnom internetskom stranicom iz odabranih djelatnosti prerađivačke industrije te se radi o namjernom uzorku. Poduzeća su kategorizirana prema Nacionalnoj klasifikaciji djelatnosti pri čemu su obuhvaćene sljedeće djelatnosti: Proizvodnja ostalih prehrambenih proizvoda (C10.8), Proizvodnja odjeće (C14), Proizvodnja kože i srodnih proizvoda od drugih materijala (C15), Proizvodnja nakita, imitacije nakita (bižuterije) i srodnih proizvoda (C32.1) te Proizvodnja sredstava za pranje, čišćenje i poliranje (C20.4) (Vlada Republike Hrvatske, 2024). Odabir navedenih djelatnosti omogućuje analizu poduzeća koja posluju u različitim segmentima prerađivačke industrije, a čiji proizvodi potencijalno mogu biti predmet online prodaje i plasmana na inozemna tržišta.

Podaci su prikupljeni iz više javno dostupnih izvora, uključujući baze FINA Info.BIZ, CompanyWall i Fininfo, kao i službene mrežne stranice analiziranih poduzeća. Korištenjem više izvora nastojala se povećati pouzdanost prikupljenih podataka te omogućiti detaljniji uvid u osnovna obilježja poduzeća, njihovu prisutnost u online okruženju i elemente povezane s međunarodnom tržišnom orijentacijom. Za svako poduzeće prikupljeni su podaci o pravnom obliku, NKD klasifikaciji, starosti poduzeća, sjedištu poduzeća i broju zaposlenika. Osim osnovnih obilježja poduzeća, analizirana je i prisutnost online prodaje, odnosno informacija o tome ima li poduzeće uspostavljen neki oblik online prodaje. Kod poduzeća kod kojih je utvrđeno postojanje online prodaje dodatno je evidentiran oblik, odnosno kanal online prodaje. Posebna pozornost posvećena je funkcionalnostima internetske prodavaonice; jezičnoj prilagodbi, mogućnosti prekogranične dostave i geografskom dosegu dostave, valuti u kojoj su prikazane cijene te podržanim načinima plaćanja. Postupak kodiranja i definicije varijabli razvidne su iz kodne knjige prikazane u Tablici 1. Internetska prodavaonica smatra se funkcionalnom ako su u njoj prikazani proizvodi i njihove cijene, ako omogućuje dodavanje proizvoda u funkcionalnu košaricu te ako su navedeni dostupni načini plaćanja i omogućena dostava proizvoda. Prikupljeni podaci omogućili su ispitivanje povezanosti između djelatnosti poduzeća i postojanja online prodaje, između jezične prilagodbe internetske prodavaonice i mogućnosti prekogranične dostave te između geografskog dosega dostave i broja dostupnih načina plaćanja.

Tablica 1. Kodna knjiga

Varijabla	Definicija	Kriterij kodiranja
Postojanje online prodaje	Mogućnost pokretanja i dovršavanja kupnje proizvoda putem interneta .	0 = online kupnja nije omogućena; 1 = omogućena je kupnja putem najmanje jednog digitalnog prodajnog kanala
Mogućnost prekogranične dostave	Dostupnost dostave proizvoda izvan RH.	0 = dostava proizvoda unutar granica RH; 1=dostava proizvoda izvan granica RH
Geografski doseg dostave	Područje dostave proizvoda kupljenih putem internetske prodavaonice.	0 = dostava je moguća samo u RH; 1 = dostava je moguća u barem jednu državu izvan RH

Jezična prilagodba	Dostupnost sadržaja internetske prodavaonice na jeziku stranom jeziku.	0 = samo hrvatski; 1 = najmanje jedan strani jezik
Broj dostupnih načina plaćanja	Broj međusobno različitih načina plaćanja dostupnih u postupku kupnje.	0 = jedan ili dva načina; 1 = tri ili više načina

Izvor: Vlastita izrada autora

U skladu s ciljevima istraživanja definirane su tri istraživačke hipoteze. Prva hipoteza ispituje postoji li statistički značajna povezanost između djelatnosti poduzeća i postojanja online prodaje. Druga hipoteza usmjerena je na ispitivanje povezanosti između jezične prilagodbe internetske prodavaonice i mogućnosti prekogranične dostave, dok treća hipoteza ispituje povezanost između geografskog dosega dostave i raznolikosti ponuđenih načina plaćanja. Ograničenje istraživanja proizlazi iz činjenice da se analiza temelji na javno dostupnim podacima, zbog čega nije moguće sa sigurnošću utvrditi sve aspekte stvarnog poslovanja poduzeća, posebice u slučajevima u kojima mrežne stranice nisu ažurirane ili ne sadržavaju potpune informacije o uvjetima prodaje, dostavi i plaćanju. Unatoč navedenom ograničenju, odabrani pristup omogućuje uvid u vidljivu razinu razvijenosti online prodaje i međunarodne orijentacije hrvatskih mikro, malih i srednjih poduzeća u odabranim djelatnostima prerađivačke industrije.

4. REZULTATI I DISKUSIJA

U ovom se poglavlju prikazuju rezultati empirijskog istraživanja provedenog na uzorku hrvatskih mikro, malih i srednjih poduzeća iz odabranih djelatnosti prerađivačke industrije. Najprije se iznose osnovna obilježja uzorka i deskriptivni pokazatelji razvijenosti online prodaje, nakon čega se prikazuju rezultati hi-kvadrat testa nezavisnosti za definirane istraživačke hipoteze.

4.1. DESKRIPTIVNA ANALIZA

Deskriptivna analiza provedena je na uzorku od 87 hrvatskih mikro, malih i srednjih poduzeća iz odabranih djelatnosti prerađivačke industrije. Prema pravnom obliku, najveći dio uzorka čine društva s ograničenom odgovornošću (d.o.o.), odnosno 82 poduzeća (94,25 %), dok su u uzorku zastupljena i četiri jednostavna društva s ograničenom odgovornošću (j.d.o.o.) te jedno dioničko društvo (d.d.). Tablica 2. prikazuje kako je uzorak ravnomjerno raspoređen u tri skupine djelatnosti, pri čemu svaka skupina obuhvaća 29 poduzeća. Prvu skupinu čine poduzeća iz djelatnosti Proizvodnja ostalih prehrambenih proizvoda (C10.8). Drugu skupinu čine poduzeća iz djelatnosti Proizvodnje odjeće (C14), Proizvodnje kože i srodnih proizvoda od drugih materijala (C15) te Proizvodnje nakita, imitacije nakita (bižuterije) i srodnih proizvoda (C32.1). Treću skupinu čine poduzeća iz djelatnosti Proizvodnje sredstava za pranje, čišćenje i poliranje (C20.4). Medijalna vrijednost starosti poduzeća najviša je u skupini poduzeća modne industrije te iznosi 28 godina, dok je u skupini C10.8 medijalna vrijednost starosti 13 godina, a u skupini C20.4 10 godina. S obzirom na broj zaposlenika, najviša medijalna vrijednost zabilježena je također u skupini poduzeća modne industrije te iznosi 36 zaposlenika. U skupini C10.8 medijan broja zaposlenika iznosi 9, dok je u skupini C20.4 najniži i iznosi 4 zaposlenika.

Tablica 2. Osnovna obilježja uzorka prema skupinama djelatnosti

	C10.8	C14,15,32.1	C20.4	Ukupno
Broj poduzeća	29	29	29	87
Medijalna starost	13	28	10	-
Medijalni broj zaposlenika	9	36	4	-


Izvor: Vlastita izrada autorica

Slika 1. prikazuje teritorijalnu zastupljenost poduzeća u uzorku prema županijama. Poduzeća iz uzorka nisu ravnomjerno raspoređena na području Republike Hrvatske, već je vidljiva izraženija koncentracija u Gradu Zagrebu i Zagrebačkoj županiji. Najveći broj poduzeća nalazi se u Gradu Zagrebu, gdje je evidentirano 27 poduzeća, odnosno 31,0 % ukupnog uzorka. Slijedi Zagrebačka županija s 19 poduzeća (21,8 %), dok je treća najzastupljenija Splitsko-dalmatinska županija s 10 poduzeća (11,5 %). Među županijama koje su zastupljene u uzorku, najmanju zastupljenost imaju one s po jednim poduzećem. To su Koprivničko-križevačka, Vukovarsko-srijemska, Osječko-baranjska, Brodsko-posavska, Zadarska, Sisačko-moslavačka i Dubrovačko-neretvanska županija. U uzorku nisu zastupljene Karlovačka, Ličko-senjska, Požeško-slavonska i Šibensko-kninska županija. Navedena raspodjela upućuje na teritorijalnu koncentraciju promatranih poduzeća u gospodarski razvijenijim i urbaniziranim područjima, osobito u širem zagrebačkom području.

Slika 1. Teritorijalna zastupljenost poduzeća u uzorku prema županijama (N=87)

ZASTUPLJENOST PODUZEĆA PO ŽUPANIJAMA (UKUPNO 87 PODUZEĆA)

ŽUPANIJA	BROJ PODUZEĆA	UDIO (%)
Grad Zagreb	27	31,0%
Zagrebačka županija	19	21,8%
Splitsko-dalmatinska županija	10	11,5%
Medimurska županija	7	8,0%
Primorsko-goranska županija	6	6,9%
Varaždinska županija	4	4,6%
Krapinsko-zagorska županija	4	4,6%
Virovitičko-podravska županija	2	2,3%
Bjelovarsko-bilogorska županija	2	2,3%
Istarska županija	2	2,3%
Koprivničko-križevačka županija	1	1,1%
Vukovarsko-srijemska županija	1	1,1%
Osječko-baranjska županija	1	1,1%
Brodsko-posavska županija	1	1,1%
Zadarska županija	1	1,1%
Sisačko-moslavačka županija	1	1,1%
Dubrovačko-neretvanska županija	1	1,1%
UKUPNO	87	100%



Izvor: Vlastita izrada autora prema podacima Fininfo

Rezultati analize pokazuju da 64 od ukupno 87 poduzeća ima neki oblik online prodaje. Vlastitu internetsku prodavaonicu ima 63 poduzeća, dok je kod 62 poduzeća utvrđeno da je internetska prodavaonica funkcionalna. Od 62 poduzeća s funkcionalnom internetskom prodavaonicom,

njih 41 (66,1%) omogućuje dostavu izvan Republike Hrvatske. Internetska prodavaonica na stranom jeziku dostupna je kod 38 poduzeća, dok 26 poduzeća nudi tri ili više načina plaćanja. Promatrano prema djelatnostima, najveći broj poduzeća s online prodajom nalazi se u skupini C20.4, u kojoj 26 od 29 poduzeća ima online prodaju od kojih 25 ima funkcionalnu internetsku prodavaonicu. U istoj skupini 19 poduzeća omogućuje dostavu izvan Republike Hrvatske. Opciju jezične prilagodbe internetske prodavaonice nudi 17 poduzeća. U skupini C10.8 internetsku prodavaonicu ima 20 poduzeća, od kojih 19 ima funkcionalnu internetsku prodavaonicu, a 10 poduzeća omogućuje dostavu izvan Republike Hrvatske i ima internetsku prodavaonicu dostupnu na stranom jeziku. U skupini poduzeća iz modne industrije online prodaju i internetsku prodavaonicu ima 18 poduzeća, pri čemu su sve evidentirane internetske prodavaonice funkcionalne, 12 poduzeća omogućuje dostavu izvan Republike Hrvatske, a 11 ih ima internetsku prodavaonicu dostupnu na stranom jeziku. Raznolikost načina plaćanja, mjerena dostupnošću tri ili više načina plaćanja, najčešće je zabilježena u skupinama poduzeća iz modne industrije i djelatnosti proizvodnje sredstava za pranje, čišćenje i poliranje u kojima po 10 poduzeća nudi tri ili više načina plaćanja, dok je u skupini C10.8 takvih poduzeća šest. U pogledu prilagodbe međunarodnim kupcima, skupina C20.4 pokazuje najvišu razinu razvijenosti promatranih obilježja, osobito prema broju poduzeća s online prodajom, funkcionalnom internetskom prodavaonicom, dostavom izvan Republike Hrvatske i dostupnošću internetske prodavaonice na stranom jeziku. Što se tiče valute iskazivanja cijena, u analiziranom uzorku izrazito prevladava euro. Ukupno 84 poduzeća cijene proizvoda iskazuju u eurima, dok jedno poduzeće cijene iskazuju u američkim dolarima. Jedno poduzeće još uvijek primjenjuje dvojno iskazivanje cijena u kunama i eurima, a samo jedno poduzeće prilagođava valutu zemlji kupca, i to u slučaju kupaca iz Republike Srbije, kojima se cijene prikazuju u srpskim dinarima (RSD). Navedeni rezultati upućuju na to da je valutna prilagodba kupcima izvan europodručja u promatranom uzorku vrlo rijetko zastupljena.

Tablica 3. Obilježja online prodaje prema skupinama djelatnosti

	C10.8	C14,15,32.1	C20.4	Ukupno
Online prodaja	20	18	26	64
Internetska prodavaonica	20	18	25	63
Funkcionalna internetska prodavaonica	19	18	25	62
Dostava izvan RH	10	12	19	41
Dostupna internetska prodavaonica na stranom jeziku	10	11	17	38
3+ dostupnih načina plaćanja	6	10	10	26

Izvor: Vlastita izrada autora

4.2. TESTIRANJE ISTRAŽIVAČKIH HIPOTEZA

U ovom poglavlju predstavljene su istraživačke hipoteze te postupci njihova testiranja. Dobiveni rezultati potom su prikazani, interpretirani i razmotreni u kontekstu prethodnih istraživanja.

H1: Postoji statistički značajna povezanost između djelatnosti poduzeća i postojanja online prodaje.

U ukupnom uzorku online prodaju ima 64 od 87 poduzeća (73,6 %). Promatrano prema djelatnostima, najveći udio poduzeća s online prodajom zabilježen je u skupini C20.4, u kojoj

online prodaju ima 26 od 29 poduzeća (89,7 %). U skupini C10.8 online prodaju ima 20 od 29 poduzeća (69,0 %), dok je najniži udio zabilježen u skupini proizvođača iz modne industrije, u kojoj online prodaju ima 18 od 29 poduzeća (62,1 %).

Tablica 4. Opažene frekvencije prema djelatnosti poduzeća i postojanju online prodaje

	Poduzeća s online prodajom	Poduzeća bez online prodaje	Ukupno
C10.8	20	9	29
C14/C15/C32.1	18	11	29
C20.4	26	3	29
Ukupno	64	23	87

Izvor: Vlastita izrada autora

Rezultati hi-kvadrat testa nezavisnosti pokazuju da se postojanje online prodaje statistički značajno razlikuje s obzirom na djelatnost poduzeća. Drugim riječima, djelatnost poduzeća povezana je s postojanjem online prodaje, uz vrijednost testa 6,147 i p-vrijednost 0,046. Vrijednost Cramérova V iznosi 0,266 te upućuje na povezanost slabe do umjerene jačine. Test je proveden uz dva stupnja slobode, što proizlazi iz strukture kontingencijske tablice s trima skupinama djelatnosti i dvjema kategorijama postojanja online prodaje. Pritom je zadovoljena pretpostavka o očekivanim frekvencijama, budući da nijedna očekivana frekvencija u ćelijama kontingencijske tablice nije bila manja od 5. Isti je uvjet bio zadovoljen i pri testiranju preostalih dviju hipoteza, što upućuje na prikladnost primjene hi-kvadrat testa nezavisnosti u svim provedenim analizama. Navedeni rezultati upućuju na to da je online prodaja u promatranom uzorku relativno zastupljenija kod poduzeća iz djelatnosti C20.4, dok je relativno manje zastupljena kod poduzeća iz skupine proizvođača iz modne industrije.

Tablica 5. Rezultati hi-kvadrat testa povezanosti djelatnosti poduzeća i postojanja online prodaje

P-vrijednost	χ^2	Cramérov V
0,046	6,147	0,266

Izvor: Vlastita izrada autora

Relevantnost dobivenih rezultata potvrđuju i preporuke Hamada i sur. (2018), koji kao ograničenje svojega istraživanja o prihvaćanju B2B e-trgovine navode izostanak djelatnosti poduzeća iz analitičkog modela te preporučuju njezino uključivanje u buduća istraživanja. Strzelecki (2019) također ističe da je njegovo istraživanje provedeno samo u jednoj djelatnosti te preporučuje obuhvaćanje većeg broja djelatnosti. Ovo istraživanje nadopunjuje njihove nalaze pokazujući da postoji statistički značajna, iako slaba do umjerena, povezanost između djelatnosti poduzeća i postojanja online prodaje, što sugerira da njezina zastupljenost može ovisiti o specifičnostima djelatnosti i karakteristikama proizvoda. Takav je nalaz u skladu s literaturom koja ističe da mogućnosti razvoja prekogranične e-trgovine nisu jednake za sve sektore, već ovise o obilježjima proizvoda, logističkim zahtjevima i načinu pristupa kupcima (Cassia & Magno, 2022). Iako ovo istraživanje ne omogućuje utvrđivanje uzroka uočenih razlika, rezultati upućuju na postojanje sektorskih specifičnosti koje mogu utjecati na razvoj online prodaje.

H2: Postoji statistički značajna povezanost između jezične prilagodbe internetske prodavaonice i mogućnosti prekogranične dostave.

U ukupnom uzorku poduzeća s funkcionalnom internetskom prodavaonicom 41 od 62 poduzeća (66,1 %) dostavlja svoje proizvode izvan Republike Hrvatske. Od 37 poduzeća s jezičnom prilagodbom internetske prodavaonice, njih 31 (83,8 %) omogućuje dostavu izvan Republike Hrvatske. Suprotno tome, među 25 poduzeća bez jezične prilagodbe internetske prodavaonice dostavu izvan Republike Hrvatske omogućuje samo 10 poduzeća (40,0 %), dok je 15 poduzeća (60,0 %) orijentirano isključivo na domaće tržište. Usporedbom opaženih i očekivanih frekvencija, među poduzećima s jezičnom prilagodbom utvrđen je znatno veći broj inozemno orijentiranih poduzeća od očekivanoga u slučaju nepostojanja povezanosti između promatranih varijabli.

Tablica 6. Opažene frekvencije prema jezičnoj prilagodbi internetske prodavaonice i mogućnosti prekogranične dostave

	Dostava izvan RH	Dostava unutar RH	Ukupno
Ima jezične prilagodbe	31	6	37
Nema jezične prilagodbe	10	15	25
Ukupno	41	21	62

Izvor: Vlastita izrada autora

Za ispitivanje povezanosti između jezične prilagodbe internetske prodavaonice i orijentacije prema inozemnim tržištima također je proveden hi-kvadrat test nezavisnosti. Rezultati testa pokazali su statistički značajnu povezanost između promatranih varijabli, $\chi^2(1) = 12,77$, $p < 0,001$, dok Cramerov V iznosi 0,45 te upućuje na umjerenu do snažnu povezanost između jezične prilagodbe internetske prodavaonice i mogućnosti prekogranične dostave. Time se potvrđuje da poduzeća s jezično prilagođenom internetskom prodavaonicom značajno češće nude opciju prekogranične dostave proizvoda.

Tablica 7. Rezultati hi-kvadrat testa povezanosti jezične prilagodbe internetske prodavaonice i mogućnosti prekogranične dostave proizvoda

P-vrijednost	χ^2	Cramérov V
0,001	12,77	0,45

Izvor: Vlastita izrada autora

Navedeni rezultat u skladu je s nalazima Strzeleckog (2019), koji je jezičnu prilagodbu internetske prodavaonice izdvojio kao jedno od ključnih obilježja prilagodbe prekograničnoj e-trgovini, što dodatno potvrđuje njezinu važnost u privlačenju i usluživanju kupaca na inozemnim tržištima. Dobiveni rezultat podupiru Chen i Kim (2021), koji su utvrdili da teškoće povezane sa stranim jezikom povećavaju percipiranu udaljenost prema stranim internetskim prodavačima te dovode do odgađanja kupnje. Singh, Furrer i Ostinelli (2004) također su pokazali da potrošači preferiraju jezično prilagođene internetske stranice naspram standardiziranih, pri čemu takva prilagodba značajno pozitivno utječe na stav prema internetskoj stranici i namjeru ponovne kupnje. Jezična prilagodba stoga može upućivati na usmjerenost poduzeća prema potrebama inozemnih kupaca i njegovu spremnost za nastup na stranim tržištima, odnosno predstavljati jedan od preduvjeta potencijalne internacionalizacije putem online prodaje.

H3: Postoji povezanost između geografskog dosega dostave i raznolikosti ponuđenih načina plaćanja.

U skupini poduzeća orijentiranih na domaće tržište 38,1 % poduzeća nudi tri ili više načina plaćanja. U skupini orijentiranoj na tržište EU taj udio iznosi 47,06 %, dok među poduzećima orijentiranim na tržišta izvan EU iznosi 50,0 %. Iako je vidljiv blagi porast udjela poduzeća s tri ili više načina plaćanja s povećanjem međunarodnog dosega, razlike nisu statistički značajne.

Tablica 8. Opažene frekvencije prema geografskom dosegu dostave i broju dostupnih načina plaćanja

	Manje od 3 načina plaćanja	Tri i više načina plaćanja	Ukupno
Dostava unutar RH	13	8	21
Dostava u EU	9	8	17
Dostava unutar i/ili izvan EU	12	12	24
Ukupno	34	28	62

Izvor: Vlastita izrada autora

Za ispitivanje povezanosti između geografskog dosega dostave i raznolikosti ponuđenih načina plaćanja također je proveden hi-kvadrat test nezavisnosti. Rezultati testa nisu pokazali statistički značajnu povezanost između promatranih varijabli, $\chi^2(2) = 0,68$, $p = 0,71$. Također, vrijednost Cramérova koeficijenta 0,104 upućuje na vrlo slabu razinu povezanosti. Time se ne može potvrditi hipoteza o povezanosti geografskog dosega dostave i raznolikosti ponuđenih načina plaćanja.

Tablica 9. Rezultati hi-kvadrat testa povezanosti geografskog dosega dostave i broja dostupnih načina plaćanja

P-vrijednost	χ^2	Cramérov V
0,71	0,68	0,104

Izvor: Vlastita izrada autora

Iako literatura naglašava važnost dostupnosti različitih digitalnih načina plaćanja za razvoj prekogranične e-trgovine (Meng & Xiao, 2025; Strzelecki, 2019), rezultati ovog istraživanja ne potvrđuju njihovu statistički značajnu povezanost s geografskim dosegom dostave poduzeća. Jedno od mogućih objašnjenja jest da su različiti načini plaćanja postali uobičajena funkcionalnost internetskih prodavaonica, neovisno o tome posluju li poduzeća pretežito na domaćem ili na inozemnim tržištima. Dodatno, moguće je da sam broj ponuđenih načina plaćanja nije dovoljno precizan pokazatelj njihove međunarodne funkcionalnosti. Naime, broj od tri ili više ponuđenih načina plaćanja ne razlikuje nužno metode prilagođene isključivo domaćem tržištu (primjerice plaćanje pouzecom ili plaćanje putem domaćih internetskih bankarstava) od onih koje omogućuju sigurno i praktično prekogranično plaćanje (primjerice međunarodne kartice ili e-novčanik), na što upućuju Meng i Xiao (2025). Buduća istraživanja stoga bi trebala razlikovati vrstu, a ne samo broj ponuđenih načina plaćanja, kako bi se preciznije utvrdilo predstavlja li raznolikost plaćanja stvaran pokazatelj međunarodne prilagođenosti poduzeća. Stoga se raznolikost načina plaćanja sama po sebi ne može smatrati pouzdanim pokazateljem geografskog dosega dostave.

5. ZAKLJUČAK

Rezultati istraživanja pokazuju da je online prodaja relativno zastupljena među analiziranim hrvatskim proizvodnim mikro, malim i srednjim poduzećima, no razvijenost elemenata koji upućuju na međunarodnu tržišnu orijentaciju nije jednako izražena u svim djelatnostima. Najviša razina zastupljenosti online prodaje i pojedinih obilježja prilagodbe međunarodnim kupcima zabilježena je kod poduzeća iz djelatnosti Proizvodnja sredstava za pranje, čišćenje i poliranje (C20.4), dok je niža zastupljenost online prodaje utvrđena kod poduzeća iz skupine modne industrije. Posebno važnim pokazateljem međunarodne orijentacije pokazala se jezična prilagodba internetske prodavaonice, budući da su poduzeća s internetskom prodavaonicom dostupnom na stranom jeziku znatno češće usmjerena prema inozemnim tržištima.

Ograničenja rada proizlaze iz veličine i strukture uzorka, usmjerenosti na odabrane djelatnosti prerađivačke industrije te oslanjanja na javno dostupne podatke. Budući da uzorak obuhvaća 87 poduzeća iz nekoliko unaprijed odabranih djelatnosti, rezultati pružaju uvid u promatrani segment MSP-ova iz prerađivačke industrije, ali se ne mogu izravno generalizirati na sva hrvatska proizvodna poduzeća. Oslanjanje na javno dostupne izvore omogućuje transparentnu analizu, ali zaključke ograničava na informacije dostupne u poslovnim bazama i na mrežnim stranicama poduzeća u trenutku istraživanja. Budući da mrežne stranice mogu biti neažurirane ili nepotpune, rezultate treba tumačiti kao pokazatelje vidljive razine razvijenosti online prodaje i prilagodbe međunarodnim kupcima, a ne kao potpunu mjeru stvarne izvozne aktivnosti ili ukupne internacionalizacije poduzeća. Rezultati sugeriraju da online prodaja može predstavljati početni korak u procesu internacionalizacije hrvatskih proizvodnih MSP-ova. Iako sama prisutnost internetske prodavaonice ne znači nužno ostvareni izvoz, elementi poput višejezičnosti, međunarodne dostave i prilagodbe korisničkog iskustva mogu se promatrati kao indikatori organizacijske spremnosti za nastup na inozemnim tržištima.

Preporuka za buduća istraživanja jest uključivanje dodatnih pokazatelja, poput ostvarenog izvoza, udjela inozemnih kupaca, vrijednosti prodaje putem digitalnih kanala te konkretnih vrsta ponuđenih načina plaćanja i njihove dostupnosti kupcima na različitim inozemnim tržištima. Time bi se omogućilo potpunije razumijevanje odnosa između online prodaje i stvarne međunarodne tržišne aktivnosti poduzeća. Rad ima praktične implikacije jer upućuje na elemente koje proizvodni MSP-ovi mogu unaprijediti kako bi povećali dostupnost stranim kupcima, osobito jezičnu prilagodbu, jasne informacije o dostavi, funkcionalnost internetske prodavaonice i međunarodno prihvatljive načine plaćanja. Nalazi mogu biti korisni poduzećima, institucijama potpore i kreatorima politika usmjerenima na jačanje digitalne i izvozne spremnosti hrvatskih MSP-ova.

ZAHVALA

Ovaj rad izrađen je u okviru IRI projekta „AI platforma nove generacije za sigurnu i održivu prodaju u složenim industrijama – Quoka CPQ“ (2186-62-14-25-33). Projekt je sufinanciran sredstvima Europske unije iz Europskog fonda za regionalni razvoj.

REFERENCE

1. Alegre, J., Ferreras-Méndez, J. L., Fernández-Mesa, A., & Strange, R. (2022). Innovation capabilities and export performance in manufacturing SMEs. *Tec Empresarial*, 16(3), 55-71. <https://doi.org/10.18845/te.v16i3.6367>
2. Calheiros-Lobo, N., Vasconcelos Ferreira, J., & Au-Yong-Oliveira, M. (2023). SME internationalization and export performance: A systematic review with bibliometric analysis. *Sustainability*, 15(11), 1-36. <https://doi.org/10.3390/su15118473>
3. Cassia, F., & Magno, F. (2022). Cross-border e-commerce as a foreign market entry mode among SMEs: the relationship between export capabilities and performance. *Review of International Business and Strategy*, 32(2), 267-283. <https://doi.org/10.1108/RIBS-02-2021-0027>
4. Chen, X., & Kim, H.-M. (2021). Antecedents and consequence of the consumer's psychic distance in cross-border e-commerce. *International Trade, Politics and Development*, 5(2), 156–173. <https://doi.org/10.1108/ITPD-08-2021-0008>
5. CompanyWall. (n.d.). CompanyWall Business. Pristupljeno 08.6.2026. s <https://www.companywall.hr/>
6. Dallochio, M., Lambri, M., Sironi, E., & Teti, E. (2024). The role of digitalization in cross-border e-commerce performance of italian SMEs. *Sustainability*, 16(2), 1-17. <https://doi.org/10.3390/su16020508>
7. Državni zavod za statistiku. (2026). Robna razmjena Republike Hrvatske s inozemstvom - privremeni podaci od siječnja do prosinca 2025. i za siječanj 2026. Pristupljeno 10.6. 2026. s <https://podaci.dzs.hr/2025/hr/97247>
8. Europska komisija. (2025). Study of the European Union SMEs internationalisation strategy: Final report. Ured za publikacije Europske unije. <https://doi.org/10.2873/9687786>
9. Europska unija. (n.d.). Micro, small and medium-sized enterprises: Definition and scope. EUR-Lex. Pristupljeno 10.6.2026. s <https://eur-lex.europa.eu/EN/legal-content/summary/micro-small-and-medium-sized-enterprises-definition-and-scope.html>
10. Financijska agencija (FINA). (n.d.). FINA. Pristupljeno 09.6.2026. s <https://www.fina.hr/>
11. Fininfo. (n.d.). FININFO. Pristupljeno 09.6.2026. s <https://www.fininfo.hr/home>
12. Hamad, H., Elbeltagi, I., & El-Gohary, H. (2018). An empirical investigation of business-to-business e-commerce adoption and its impact on SMEs competitive advantage: The case of Egyptian manufacturing SMEs. *Strategic Change*, 27(3), 209–229. <https://doi.org/10.1002/jsc.2196>
13. Ho, B. D., & Nguyen, T. (2024). Institutional quality and internationalization: Empirical evidence from manufacturing SMEs in Vietnam. *Economies*, 12(6), 1-17. <https://doi.org/10.3390/economies12060144>
14. Meng, F., & Xiao, Y. (2025). The impact of digital finance on the development of cross-border e-commerce. *Journal of Theoretical and Applied Electronic Commerce Research*, 20(3), 1-22. <https://doi.org/10.3390/jtaer20030180>
15. OECD. (n.d.). SME indicators, benchmarking and monitoring. Preuzeto 10.6. 2026. s <https://www.oecd.org/en/topics/sub-issues/sme-indicators-benchmarking-and-monitoring.html>
16. Pan, L., Fu, X., & Li, Y. (2023). SME participation in cross-border e-commerce as an entry mode to foreign markets: A driver of innovation or not? *Electronic Commerce Research*, 23(4), 2327-2356. <https://doi.org/10.1007/s10660-022-09539-7>

17. Singh, N., Furrer, O., & Ostinelli, M. (2004). To localize or to standardize on the Web: Empirical evidence from Italy, India, Netherlands, Spain, and Switzerland. *Multinational Business Review*, 12(1), 69–88. <https://doi.org/10.1108/1525383X200400004>
18. Strzelecki, A. (2019). Key features of e-tailer shops in adaptation to cross-border e-Commerce in the EU. *Sustainability*, 11(6), 1-13. <https://doi.org/10.3390/su11061589>
19. Vlada Republike Hrvatske. (2024). Odluka o Nacionalnoj klasifikaciji djelatnosti 2025. – NKD 2025. *Narodne novine*, 47/2024. Pristupljeno 09.6.2026 https://narodne-novine.nn.hr/clanci/sluzbeni/2024_04_47_800.html

Preliminary communication / Prethodno priopćenje

PERCIPIRANI RIZIK I INFORMACIJSKI ELEMENTI U ONLINE KUPNJI PARFEMA: EMPIRIJSKA ANALIZA POTROŠAČKOG ODLUČIVANJA

LORENA LONGIN

Sveučilište Sjever
Jurja Križanića 31b, 42000 Varaždin, Hrvatska
lolongin@unin.hr

BILJANA MARKOVIĆ

Sveučilište Sjever
Jurja Križanića 31b, 42000 Varaždin, Hrvatska
bimarkovic@unin.hr

JELENA BLAŽI

Sveučilište Sjever
Jurja Križanića 31b, 42000 Varaždin, Hrvatska
jeblazi@unin.hr

SAŽETAK

Online kupnja parfema razlikuje se od kupnje mnogih drugih proizvoda jer kupac prije kupnje ne može isprobati miris. Iako su mu dostupni cijena, ambalaža, opis mirisnih nota, brend i recenzije drugih kupaca, odluku ipak donosi bez izravnog iskustva s proizvodom. Zbog toga online kupnja parfema uključuje određenu nesigurnost, osobito kada kupac nije siguran hoće li mu odabrani miris odgovarati. U radu se ispituje povezanost nemogućnosti prethodnog isprobavanja, percipiranog rizika i informacijskih elemenata sa sklonošću potrošača prema online kupnji parfema. Istraživanje je provedeno online anketom na uzorku od 166 ispitanika. Podaci su obrađeni deskriptivnom statistikom, Spearmanovom korelacijom, Mann-Whitney U testom i hi-kvadrat testom. Rezultati pokazuju da ispitanici koji snažnije ističu nemogućnost isprobavanja i strah da parfem neće odgovarati očekivanjima rjeđe kupuju parfeme online te su manje spremni kupovati bez prethodnog testiranja. Informacijski elementi nemaju jednaku ulogu: opis mirisa pomaže kupcu da stekne osnovnu predodžbu o proizvodu, dok su recenzije drugih kupaca jače povezane s povjerenjem u online marketing i spremnošću na kupnju bez prethodnog testiranja. Digitalni sadržaji ne mogu zamijeniti fizičko isprobavanje parfema, ali mogu smanjiti dio nesigurnosti i pomoći kupcu da odluku donese sigurnije.

KLJUČNE RIJEČI: online kupnja, parfem, percipirani rizik, informacijski elementi, recenzije kupaca, potrošačko odlučivanje

1. UVOD

Online kupnja potrošačima olakšava dolazak do proizvoda, usporedbu cijena i čitanje iskustava drugih kupaca. Kod parfema je, međutim, situacija posebna. Kupac prije kupnje može vidjeti bočicu, cijenu, brend i opis mirisa, ali ne može provjeriti ono što je za ovu kategoriju proizvoda presudno - odgovara li mu miris. Zbog toga se kod online prodaje parfema javlja potreba za premošćivanjem razlike između kupnje putem interneta i odlaska u trgovinu radi isprobavanja proizvoda. Taj je problem važan jer se parfem ne bira samo prema funkcionalnim obilježjima. Uz sam miris, na odluku mogu utjecati cijena, akcija ili popust, ambalaža, brend, mirisne note i iskustva drugih kupaca, ali nijedan od tih elemenata ne uklanja u potpunosti mogućnost pogrešnog odabira. U fizičkoj trgovini kupac dio te nesigurnosti smanjuje isprobavanjem. U online okruženju odluku mora donijeti na temelju informacija koje su mu dostupne prije kupnje. U literaturi o e-trgovini percipirani rizik povezuje se s povjerenjem i spremnošću potrošača da prihvati online kupnju (Pavlou, 2003). Kod parfema taj rizik ima dodatnu dimenziju jer nije vezan samo uz prodavatelja ili sigurnost transakcije, nego uz pitanje hoće li konkretan miris odgovarati očekivanjima. Barbosa i sur. (2021) također ističu da je nemogućnost testiranja jedan od glavnih nedostataka online kupnje parfema, osobito kada kupac parfem prethodno nije koristio. Cilj rada je ispitati povezanost percipiranog rizika, nemogućnosti prethodnog isprobavanja i informacijskih elemenata sa sklonošću potrošača prema online kupnji parfema. Doprinos rada je u povezivanju online kupnje parfema s problemom iskustvenog proizvoda, rizikom izvedbe i ulogom digitalnih informacija koje mogu ublažiti, ali ne i ukloniti nesigurnost kupnje bez isprobavanja.

2. TEORIJSKI OKVIR

Online kupnja promijenila je način na koji potrošači traže informacije, uspoređuju proizvode i donose odluku o kupnji. Digitalni kanali kupcu nude brz pregled ponude, cijena i iskustava drugih korisnika, ali istodobno ne uklanjaju nesigurnost koja nastaje kada se proizvod ne može neposredno procijeniti. Ta je nesigurnost posebno izražena kod proizvoda koji se ne biraju samo prema funkcionalnim obilježjima, nego i prema osobnom dojmu. Korisno teorijsko polazište za ovu temu jest razlika između dobara čija se obilježja mogu procijeniti prije kupnje i iskustvenih dobara. Nelson (1970) pokazuje da dio proizvoda potrošač može procijeniti tek nakon korištenja, a Huang, Lurie i Mitra (2009) ističu da internet može djelomično olakšati procjenu iskustvenih obilježja putem informacija, recenzija i multimedijских sadržaja. Parfem se u tom smislu može promatrati kao izrazito iskustveno dobro: kupac može prikupiti informacije, ali ključni atribut - miris - ne može stvarno provjeriti prije kupnje. U literaturi o e-trgovini percipirani rizik vezuje se uz potrošačevu procjenu mogućih negativnih posljedica kupnje, primjerice nezadovoljstva proizvodom, financijskog gubitka, problema s povratom ili neusklađenosti proizvoda s očekivanjima. Pavlou (2003) pritom ističe da se prihvaćanje elektroničke trgovine ne može razumjeti bez odnosa povjerenja i rizika. Featherman i Pavlou (2003) posebno izdvajaju rizik izvedbe kao važan aspekt prihvaćanja e-usluga, a Forsythe i Shi (2003) pokazuju da percepcije rizika u internetskoj kupnji mogu biti povezane s proizvodom, transakcijom i očekivanim ishodom kupnje. Kod parfema je taj rizik vrlo konkretan. Ne proizlazi samo iz pitanja je li online trgovina pouzdana, nego iz činjenice da kupac prije kupnje ne može provjeriti miris. Može vidjeti bočicu, cijenu, brend, mirisne note i recenzije, ali ne može biti siguran hoće li mu parfem odgovarati nakon što ga stvarno isproba. Zato se kod online kupnje parfema rizik pogrešnog odabira javlja i onda kada kupac nema poseban otpor prema kupnji putem interneta. Barbosa i sur. (2021) navode da online kupnja parfema potrošačima može biti privlačna zbog cijene, dostupnosti i većeg izbora, ali da je nemogućnost testiranja

jedan od glavnih nedostataka takve kupnje, osobito kada je riječ o parfemima koje kupac ranije nije koristio.

Parfem je pritom specifičan jer se njegovo ključno obilježje - miris - u online okruženju ne može neposredno provjeriti prije kupnje. Nemogućnost prethodnog isprobavanja stoga može povećati nesigurnost potrošača i smanjiti njegovu sklonost online kupnji parfema.

H1: Nemogućnost prethodnog isprobavanja parfema negativno je povezana sa sklonošću potrošača prema online kupnji parfema.

Kod parfema se percipirani rizik posebno odnosi na mogućnost da proizvod nakon kupnje neće odgovarati očekivanjima potrošača. Takva nesigurnost može postojati i kada potrošač nema izraženo nepovjerenje prema online trgovini kao kanalu kupnje. Stoga se pretpostavlja:

H2: Veći percipirani rizik online kupnje parfema negativno je povezan sa sklonošću potrošača prema online kupnji parfema.

U tom se kontekstu digitalni marketing ne promatra samo kao sredstvo promocije, nego i kao izvor informacija koje mogu smanjiti nesigurnost. Parfem nije proizvod koji se može svesti na ambalažu, cijenu ili naziv brenda. Mađarić (1999) ga definira kao vodeno-alkoholnu otopinu mirisnih ulja, ali za korisnika parfem najčešće ima šire značenje: može biti dio osobnog stila, svakodnevne rutine, poklon, znak individualnosti ili način stvaranja određenog dojma. Upravo zbog toga odluka o kupnji parfema često uključuje i emocionalnu i simboličku dimenziju. Osjetilna dimenzija parfema posebno je važna. Krishna (2012) osjetilni marketing povezuje s angažiranjem osjetila radi utjecaja na percepciju, prosudbu i ponašanje potrošača. Kod parfema ta veza nije usputna: miris je temeljna vrijednost proizvoda. Beg (2020) također naglašava da osjetilni marketing djeluje kroz doživljaj i emocije, što je kod parfema izravno povezano s načinom na koji kupac procjenjuje proizvod. U fizičkoj trgovini kupac može parfem isprobati, usporediti ga s drugim mirisima i procijeniti kako se razvija nakon nanošenja. Time se dio nesigurnosti smanjuje jer odluka nastaje na temelju neposrednog iskustva. U online okruženju toga nema. Kupac se mora osloniti na opis mirisa, mirisne note, fotografije, brend, cijenu i tuđa iskustva. Iako Peck i Childers (2003) primarno istražuju važnost dodira u procjeni proizvoda, njihov je pristup koristan i za ovu temu jer pokazuje koliko osjetilne informacije mogu biti važne pri donošenju kupovne odluke. Kod parfema nije riječ o dodiru, nego o mirisu, ali je problem sličan: kada potrošač ne može provjeriti ključno osjetilno obilježje proizvoda, odluka postaje nesigurnija. Čarapina Zovko i Đinkić (2022) dodatno upućuju na važnost mirisa i boje proizvoda u oblikovanju atraktivnosti kupnje, što potvrđuje da se odluka o parfemu ne temelji samo na funkcionalnim informacijama. Zbog toga online prodaja parfema traži drukčiji oblik komunikacije. Nije dovoljno navesti naziv, cijenu i nekoliko mirisnih nota. Potrošaču treba pomoći da stekne jasniju predodžbu o mirisu, intenzitetu, trajnosti i prigodi u kojoj bi se parfem mogao koristiti. Digitalni sadržaj tako barem djelomično premošćuje ono što se u trgovini rješava neposrednim isprobavanjem. Informacijski elementi u ovom radu obuhvaćaju informacije koje kupcu pomažu pri odluci o online kupnji parfema. Među njima su opis mirisa, mirisne note, recenzije drugih kupaca, fotografije, preporuke, usporedbe s poznatim mirisima te jasni uvjeti kupnje i povrata. Za razliku od općeg oglašavanja, koje često samo privlači pažnju, takve informacije kupcu pomažu da procijeni hoće li proizvod zaista odgovarati njegovim očekivanjima. Opis mirisa jedan je od osnovnih informacijskih elemenata. Kupcu može približiti je li parfem svjež, cvjetni, drvenasti, orijentalni, sladak, lagan ili intenzivan. Ipak, opis ima granice. On može pomoći u razumijevanju proizvoda, ali ne može prenijeti osobni doživljaj mirisa. Paula i sur. (2020) pokazuju da senzorna i simbolička obilježja u online opisima parfema mogu utjecati na uključenost potrošača i namjeru kupnje, što potvrđuje da način opisivanja parfema nije tek formalni dio prodajne stranice. Recenzije drugih kupaca imaju drukčiju ulogu. One ne dolaze od brenda ili prodavatelja, nego od osoba koje su parfem već

kupile ili koristile. Cheung i Thadani (2012) ističu da elektronička usmena predaja može utjecati na stavove i ponašanje potrošača, a Hennig-Thurau i sur. (2004) pokazuju da internetske platforme omogućuju potrošačima razmjenu iskustava i mišljenja s drugim korisnicima. Chevalier i Mayzlin (2006) dodatno potvrđuju važnost online recenzija jer pokazuju da tekstualni sadržaj recenzija može biti važan za potrošačko odlučivanje, a ne samo ukupna ocjena proizvoda. Novija istraživanja online kupnje parfema potvrđuju tu logiku. Argyanti, Sabil Hussein i Oktaviani (2025) pokazuju da digitalni znakovi, među njima opisi proizvoda i recenzije, mogu smanjiti nesigurnost kod online kupnje parfema bez prethodnog isprobavanja.

U takvim okolnostima opis mirisa i recenzije drugih kupaca mogu pomoći potrošaču pri procjeni proizvoda koji ne može prethodno isprobati. Opis pruža osnovne informacije o obilježjima parfema, dok recenzije prenose iskustva drugih korisnika. Očekuje se stoga da će pozitivnija procjena tih informacijskih elemenata biti povezana s većim povjerenjem i većom spremnošću na kupnju bez prethodnog testiranja.

H3: Pozitivna procjena informacijskih elemenata, osobito recenzija drugih kupaca i opisa mirisa, povezana je s većim povjerenjem u online marketing i većom spremnošću na kupnju parfema bez prethodnog testiranja.

Informacijski elementi zato ne mogu u potpunosti zamijeniti fizičko iskustvo, ali mogu pomoći kupcu da lakše procijeni rizik. Važno je razlikovati informaciju od iskustvene potvrde. Opis mirisa kupcu objašnjava proizvod, dok recenzije nude dojam drugih korisnika. U online kupnji parfema ta razlika može biti presudna: kupac ne može pomirisati parfem, ali može usporediti službeni opis s iskustvima ljudi koji su ga već isprobali. Na toj se pretpostavci temelji empirijski dio rada.

3. METODOLOGIJA ISTRAŽIVANJA

Empirijski dio rada temelji se na kvantitativnom istraživanju provedenom metodom online anketnog upitnika. Istraživanje je provedeno u razdoblju od 12. do 21. svibnja 2026. godine. Upitnik je izrađen u alatu Google Forms i distribuiran putem društvenih mreža, odnosno Facebook grupa. Sudjelovanje u istraživanju bilo je dobrovoljno i anonimno, a ispitanici su u uvodnom dijelu upitnika bili upoznati sa svrhom istraživanja. Ukupno je prikupljeno 166 odgovora.

Tablica 1. Struktura uzorka prema spolu i dobi

Obilježje	Kategorija	N	% od ukupnog uzorka
Ukupni broj ispitanika		166	100,0
Spol	Žensko	123	74,1
Spol	Muško	42	25,3
Spol	Bez odgovora	1	0,6
Dob	<18	6	3,6
Dob	18–29	94	56,6
Dob	30–49	50	30,1
Dob	50+	15	9,0
Dob	Bez odgovora	1	0,6

Izvor: Autori

Uzorak je prigodni. U istraživanju su sudjelovale 123 žene, što čini 74,1 % ukupnog uzorka, i 42 muškarca, odnosno 25,3 % uzorka, dok jedan ispitanik nije naveo spol. Prema dobi, najveći udio ispitanika pripada skupini od 18 do 29 godina (94 ispitanika; 56,6 %), zatim skupini od 30 do 49 godina (50 ispitanika; 30,1 %). U skupini starijih od 50 godina bilo je 15 ispitanika (9,0 %), dok je u skupini mlađih od 18 godina bilo 6 ispitanika (3,6 %). Jedan ispitanik nije naveo dob. Budući da je riječ o prigodnom online uzorku s izraženijom zastupljenošću žena i mlađih ispitanika, rezultate treba tumačiti u okviru ograničenja nereprezentativnog uzorka. Uzorak je sadržajno relevantan za temu istraživanja jer 102 ispitanika (61,4 %) parfem koristi svakodnevno, a dodatnih 38 ispitanika (22,9 %) nekoliko puta tjedno. Pritom je 99 ispitanika (59,6 %) već kupilo parfem online, dok njih 66 (39,8 %) to nije učinilo; po jedan odgovor nedostaje u oba pitanja. Operacionalizacija ključnih varijabli prikazana je u Tablici 2. Budući da upitnik ne sadrži validirane višestavne skale, analiza se temelji na pojedinačnim ordinalnim indikatorima koji izravno odgovaraju cilju rada i postavljenim hipotezama. S obzirom na to da su ključne varijable mjerene ordinalnim skalama, za obradu podataka korištene su neparametarske statističke metode. Najprije su prikazani deskriptivni pokazatelji, a zatim su za provjeru postavljenih hipoteza korištene bivarijatne analize. Za ispitivanje povezanosti među ordinalnim varijablama korištena je Spearmanova korelacija ranga. Za usporedbu ispitanika koji su već kupili parfem online i onih koji nisu korišten je Mann-Whitney U test. Za ispitivanje povezanosti među kategorijskim varijablama korišten je hi-kvadrat test nezavisnosti. Prag statističke značajnosti postavljen je na $p < 0,05$.

Tablica 2. Operacionalizacija ključnih varijabli

Varijabla / područje	Pokazatelj u upitniku	Skala
Sklonost online kupnji	učestalost online kupnje parfema; spremnost na kupnju bez prethodnog testiranja; prethodno iskustvo online kupnje	ordinalna 1-4; Likert 1-5; kategorijska
Nemogućnost isprobavanja	teškoća kupnje parfema online bez prethodnog isprobavanja; važnost mogućnosti isprobavanja prije kupnje	Likert /ordinalna
Percipirani rizik	strah da parfem kupljen online neće odgovarati očekivanjima	Likert 1-5
Informacijski elementi	važnost opisa mirisa; utjecaj recenzija drugih kupaca; povjerenje u online marketing	Likert /ordinalna

Izvor: Autori

Budući da pojedini ispitanici nisu odgovorili na sva pitanja, broj odgovora u pojedinim analizama neznatno varira. Analiza je usmjerena na utvrđivanje povezanosti među varijablama i razlika među skupinama, a ne na dokazivanje uzročno-posljedičnih odnosa. Zbog većeg broja provedenih bivarijatnih testova, slabije nalaze treba tumačiti oprezno i u odnosu na teorijski smisao promatranih varijabli.

4. REZULTATI ISTRAŽIVANJA

U poglavlju se prikazuju deskriptivni pokazatelji i rezultati testiranja hipoteza. Budući da su ključne varijable ordinalne, naglasak je na smjeru i jačini povezanosti, a ne na uzročno-posljedičnom tumačenju. Deskriptivni pokazatelji upućuju na glavni problem online kupnje parfema. Ispitanici vrlo visoko vrednuju prethodno isprobavanje: medijan tvrdnje da je parfem teško kupiti online bez prethodnog isprobavanja iznosi 5, jednako kao i medijan važnosti

prethodnog isprobavanja. Nasuprot tome, spremnost na kupnju parfema bez testiranja znatno je niža, s medijanom 2,5. Drugim riječima, kod parfema online kupnja nije samo pitanje dostupnosti proizvoda ili cijene, nego i pitanje koliko je kupac spreman odlučiti bez neposredne provjere mirisa.


Tablica 3. Spearmanove korelacije između ključnih varijabli

Odnos varijabli	ρ	p	Tumačenje
Teškoća bez isprobavanja – učestalost online kupnje	-0,378	<0,001	značajna negativna
Teškoća bez isprobavanja – spremnost na kupnju bez testiranja	-0,479	<0,001	umjerena negativna
Važnost prethodnog isprobavanja – učestalost online kupnje	-0,192	0,013	slaba negativna
Važnost prethodnog isprobavanja – spremnost na kupnju bez testiranja	-0,390	<0,001	umjerena negativna
Strah da parfem neće odgovarati očekivanjima – učestalost online kupnje	-0,375	<0,001	značajna negativna
Strah da parfem neće odgovarati očekivanjima – spremnost na kupnju bez testiranja	-0,257	<0,001	slaba do umjerena negativna
Opis mirisa – spremnost	0,145	0,065	nije statistički značajno
Recenzije – povjerenje	0,353	<0,001	pozitivna povezanost
Recenzije – spremnost	0,326	<0,001	pozitivna povezanost

Izvor: Autori

Prva hipoteza polazi od pretpostavke da nemogućnost prethodnog isprobavanja smanjuje sklonost online kupnji parfema. Ta je pretpostavka osobito važna kod ove kategorije proizvoda jer se odluka ne temelji samo na cijeni, brendu ili izgledu ambalaže, nego ponajprije na mirisu, koji se u online okruženju ne može provjeriti prije kupnje. Korelacijska analiza pokazuje očekivani smjer odnosa. Što ispitanici snažnije smatraju da je parfem teško kupiti online bez prethodnog isprobavanja, to rjeđe kupuju parfeme online ($\rho = -0,378$; $p < 0,001$) i manje su spremni na kupnju bez testiranja ($\rho = -0,479$; $p < 0,001$). Sličan je obrazac vidljiv i kod važnosti samog isprobavanja: ispitanici kojima je prethodno isprobavanje važnije rjeđe kupuju parfeme online ($\rho = -0,192$; $p = 0,013$) i manje su spremni kupiti parfem bez testiranja ($\rho = -0,390$; $p < 0,001$). Najjača povezanost, $\rho = -0,479$, može se tumačiti kao umjerena do relativno snažna negativna povezanost. Usporedba ispitanika koji su već kupili parfem online i onih koji to nisu učinili potvrđuje istu logiku. Ispitanici bez iskustva online kupnje parfema značajno snažnije ističu teškoću kupnje bez prethodnog isprobavanja ($U = 2186,0$; $p < 0,001$).

Slika 1. Negativne korelacije s pokazateljima online kupovne sklonosti




Izvor: Autori

Pritom razlika u samoj važnosti isprobavanja nije statistički značajna. To znači da je potreba za isprobavanjem visoka i kod onih koji su već kupovali parfeme online i kod onih koji nisu, ali rezultati upućuju na to da ispitanici s prethodnim iskustvom online kupnje lakše prihvaćaju određenu razinu rizika. Na temelju navedenih rezultata, H1 se potvrđuje. Nemogućnost prethodnog isprobavanja nije tek tehnički nedostatak online kanala, nego prepreka koja izravno utječe na način na koji potrošač procjenjuje parfem kao proizvod.

Druga hipoteza odnosi se na percipirani rizik online kupnje parfema. U ovom radu rizik se ne promatra široko, kao opće nepovjerenje prema internetu ili online trgovinama, nego konkretnije: kao strah da parfem kupljen online neće odgovarati očekivanjima. Kod parfema je takva nesigurnost razumljiva jer kupac prije kupnje ne može provjeriti miris, njegov intenzitet, trajnost ni način na koji se razvija na koži.

Slika 2. Učestalost online kupnje po razini percipiranog rizika



Napomena: Za grafički prikaz kategorije učestalosti online kupnje rekodirane su s izvorne skale 1–4 na 0–3.


Izvor: Autori

Dobiveni rezultati pokazuju da je percipirani rizik statistički značajno povezan s online kupnjom parfema. Ispitanici koji izražavaju veći strah da parfem kupljen online neće odgovarati njihovim očekivanjima rjeđe kupuju parfeme online ($\rho = -0,375$; $p < 0,001$). Isti smjer povezanosti dobiven je i kod spremnosti na kupnju bez prethodnog testiranja ($\rho = -0,257$; $p < 0,001$), iako je povezanost slabija. Posebno je važno da percipirani rizik nije statistički značajno

povezan s općim povjerenjem u online marketing ($p = 0,088$; $p = 0,260$). Taj nalaz ne upućuje na jednostavan zaključak da potrošači ne vjeruju digitalnom oglašavanju. Preciznije je reći da potrošač može prihvaćati online kanal, ali i dalje oklijevati jer ne zna hoće li mu konkretan miris odgovarati. Usporedba skupina dodatno potvrđuje ovu razliku. Ispitanici koji nisu kupovali parfeme online iskazuju višu razinu percipiranog rizika od ispitanika koji su već imali iskustvo online kupnje parfema ($U = 2154,5$; $p < 0,001$). Iskustvo online kupnje, prema tome, može smanjiti dio nesigurnosti, ali ne uklanja temeljni problem: parfem se prije kupnje i dalje ne može isprobati. Na temelju navedenih rezultata, H2 se potvrđuje. Veći percipirani rizik povezan je s nižom sklonošću online kupnji parfema, pri čemu se taj rizik ponajprije odnosi na neizvjesnost oko toga hoće li miris odgovarati očekivanjima, a ne nužno na nepovjerenje prema digitalnom kanalu kao takvom.

Treća hipoteza ispituje jesu li pozitivnije procjene informacijskih elemenata povezane s većim povjerenjem u online marketing i većom spremnošću na kupnju parfema bez prethodnog testiranja. U analizi su posebno izdvojeni opis mirisa i recenzije drugih kupaca jer upravo ti elementi najizravnije pokušavaju nadomjestiti ono što potrošaču u online okruženju nedostaje: osobno iskustvo isprobavanja. Opis mirisa pokazuje određenu, ali ograničenu ulogu. Pozitivno je povezan s procjenom da recenzije pomažu pri odluci ($p = 0,286$; $p < 0,001$) i s povjerenjem u online marketing ($p = 0,182$; $p = 0,020$). Međutim, njegova povezanost sa spremnošću na kupnju bez prethodnog testiranja nije statistički značajna ($p = 0,145$; $p = 0,065$). Opis mirisa, dakle, može pomoći kupcu da se orijentira, ali sam po sebi ne mora biti dovoljan da bi se lakše odlučio na kupnju bez isprobavanja. Recenzije drugih kupaca pokazuju snažniju i dosljedniju ulogu. Pozitivno su povezane s povjerenjem u online marketing ($p = 0,353$; $p < 0,001$), sa spremnošću na kupnju bez prethodnog testiranja ($p = 0,326$; $p < 0,001$) te s procjenom da digitalni marketing može djelomično nadomjestiti fizičko iskustvo ($p = 0,252$; $p = 0,001$). Ove su povezanosti uglavnom slabe do umjerene, ali su dosljedne i teorijski smislene jer recenzije nose iskustvenu dimenziju. Na temelju navedenih rezultata, H3 se može djelomično potvrditi. Informacijski elementi imaju važnu ulogu, ali ne djeluju jednako. Recenzije drugih kupaca pokazuju se uvjerljivijim osloncem od samog opisa mirisa, dok opis mirisa zadržava prije svega informativnu funkciju. Dodatni hi-kvadrat testovi nisu pokazali statistički značajne razlike između ispitanika koji su kupili i onih koji nisu kupili parfem online u odnosu na glavni razlog odvrćanja od kupnje, najvažniji faktor pri online kupnji, vrstu recenzija koja najviše utječe na odluku i platformu na kojoj se najčešće primjećuju oglasi za parfeme.

Slika 3. Pozitivne korelacije informacijskih elemenata



Izvor: Autori

Taj nalaz ne umanjuje važnost prethodnih rezultata, nego upućuje na to da su neke prepreke široko prisutne u cijelom uzorku. To se posebno odnosi na nemogućnost isprobavanja, koju je kao glavnu prepreku navelo 125 ispitanika, odnosno 75,3 % onih koji su odgovorili na to pitanje. Gledano u cjelini, H1 i H2 se potvrđuju, dok se H3 može djelomično potvrditi. Nemogućnost prethodnog isprobavanja i percipirani rizik pokazuju se kao važna ograničenja online kupnje parfema. Informacijski elementi imaju korisnu, ali nejednaku ulogu, pri čemu se posebno izdvajaju recenzije drugih kupaca. Ti se nalazi detaljnije tumače u nastavku rada.

5. RASPRAVA I IMPLIKACIJE

Rezultati istraživanja pokazuju da se online kupnja parfema ne može promatrati jednako kao online kupnja proizvoda čija su obilježja lako provjerljiva prije kupnje. U teorijskom smislu parfem se može promatrati kao iskustveno dobro: kupac može prikupiti informacije, ali ključni atribut proizvoda ne može provjeriti prije kupnje. Upravo tu nastaje glavni problem, odnosno strah da proizvod nakon kupnje neće odgovarati očekivanjima. Nalazi povezani s prvom hipotezom pokazuju da je nemogućnost prethodnog isprobavanja jedna od glavnih prepreka online kupnji parfema. Ispitanici koji snažnije ističu teškoću kupnje bez isprobavanja rjeđe kupuju parfeme online i manje su spremni kupiti parfem bez testiranja. To znači da se problem ne svodi samo na naviku odlaska u fizičku trgovinu, nego na potrebu da se miris prije kupnje osobno provjeri. Dobiveni rezultati u skladu su s nalazima Barbosa i sur. (2021), koji nemogućnost testiranja navode kao jedan od glavnih nedostataka online kupnje parfema, osobito kada potrošač proizvod ranije nije koristio. Nalaz je u skladu i sa širim razumijevanjem iskustvenih dobara, čija se važna obilježja ne mogu u potpunosti procijeniti prije korištenja (Nelson, 1970; Huang, Lurie i Mitra, 2009). Kod parfema je to ograničenje posebno izraženo jer je upravo miris ključno obilježje proizvoda. Druga hipoteza dodatno pojašnjava taj odnos. Strah da parfem kupljen online neće odgovarati očekivanjima negativno je povezan s učestalošću online kupnje i spremnošću na kupnju bez prethodnog testiranja. Posebno je važno što taj rizik nije značajno povezan s općim povjerenjem u online marketing. Time se dobiva preciznija slika problema: potrošač ne mora nužno imati nepovjerenje prema online trgovini ili digitalnom oglašavanju, ali i dalje može oklijevati jer ne zna hoće li mu konkretan miris odgovarati. Negativna povezanost percipiranog rizika sa sklonošću online kupnji u skladu je s ranijim istraživanjima koja rizik prepoznaju kao važan čimbenik prihvatanja elektroničke trgovine (Pavlou, 2003; Forsythe i Shi, 2003). U ovom je istraživanju posebno vidljiva dimenzija rizika izvedbe koju izdvajaju Featherman i Pavlou (2003): nesigurnost se ne odnosi toliko na samu pouzdanost digitalnog kanala koliko na mogućnost da kupljeni proizvod neće ispuniti očekivanja. Kod parfema je taj problem dodatno pojačan činjenicom da se miris ne može provjeriti prije kupnje. Treća hipoteza pokazuje da informacijski elementi mogu pomoći, ali ne jednako. Opis mirisa ima korisnu funkciju jer kupcu daje osnovnu orijentaciju o proizvodu. Može približiti mirisne note, intenzitet ili karakter parfema, ali rezultati pokazuju da sam opis nije dovoljno snažno povezan sa spremnošću na kupnju bez prethodnog testiranja. Recenzije drugih kupaca pokazale su izraženiju ulogu jer nude dojam osoba koje su parfem već koristile. Različita uloga opisa mirisa i recenzija drugih kupaca posebno je važan nalaz ovog istraživanja. Paula i sur. (2020) pokazuju da način na koji su senzorna i simbolička obilježja parfema predstavljena u online opisima može utjecati na uključenost potrošača i namjeru kupnje. Rezultati ovog istraživanja ipak pokazuju da sam opis mirisa nije statistički značajno povezan sa spremnošću na kupnju bez prethodnog testiranja. To upućuje na ograničenje opisnog sadržaja: on potrošaču može približiti proizvod, ali ne može u potpunosti zamijeniti osobni doživljaj mirisa. Nalaz o izraženijoj ulozi recenzija u skladu je s istraživanjima elektroničke usmene predaje koja pokazuju da iskustva drugih korisnika mogu utjecati na

stavove i ponašanje potrošača (Hennig-Thurau i sur., 2004; Cheung i Thadani, 2012). U skladu je i s nalazima Chevaliera i Mayzlina (2006) o važnosti sadržaja online recenzija. Posebno je relevantno istraživanje Argyanti, Sabil Hussein i Oktaviani (2025), koje pokazuje da digitalni znakovi, uključujući opise proizvoda i recenzije, mogu smanjivati nesigurnost pri online kupnji parfema. Naši rezultati pritom dodatno pokazuju da ti elementi nemaju jednaku ulogu te da se recenzije snažnije povezuju s povjerenjem i spremnošću na kupnju od samog opisa mirisa. Ovi nalazi imaju i teorijsku i praktičnu vrijednost. Teorijski, upućuju na to da se online kupnja parfema treba promatrati kroz spoj percipiranog rizika, osjetilne prirode proizvoda i digitalnih informacija koje pokušavaju nadomjestiti izostanak isprobavanja. Praktično, rezultati pokazuju da digitalno oglašavanje parfema ne bi trebalo počivati samo na lijepoj fotografiji, popustu ili kratkoj promotivnoj poruci. Dio rizika u online kupnji parfema ne može se ukloniti ni najboljim opisom ni najdetaljnijom recenzijom. Za online prodavatelje to znači da uz osnovni opis proizvoda treba osigurati sadržaje koji potrošaču pomažu u procjeni mirisa i smanjenju nesigurnosti. Posebnu vrijednost mogu imati vjerodostojne i sadržajne recenzije kupaca, jasni opisi mirisnih nota i karaktera parfema te usporedbe s poznatim mirisima. Takvi elementi ne mogu zamijeniti isprobavanje proizvoda, ali mogu smanjiti rizik odluke i olakšati procjenu odgovara li određeni parfem očekivanjima kupca.

6. ZAKLJUČAK

Online kupnja parfema dobro pokazuje ograničenja digitalnog okruženja kod proizvoda koji se temelje na osjetilnom doživljaju. Potrošač može doći do brojnih informacija o proizvodu, ali prije kupnje ne može provjeriti njegovo ključno obilježje - miris. Zbog toga se kod online prodaje parfema ne postavlja samo pitanje kako proizvod oglasiti, nego i kako smanjiti nesigurnost povezanu s mogućnošću pogrešnog odabira. Rezultati potvrđuju H1 i H2. Nemogućnost prethodnog isprobavanja i veći percipirani rizik negativno su povezani sa sklonošću online kupnji parfema. Drugim riječima, što potrošač snažnije ističe problem isprobavanja i strah da miris neće odgovarati očekivanjima, to je njegova sklonost online kupnji parfema niža. H3 se može djelomično potvrditi. Pozitivna procjena informacijskih elemenata povezana je s povjerenjem i spremnošću na kupnju, ali ne jednako kroz sve elemente. Opis mirisa potrošaču daje osnovnu orijentaciju o proizvodu, dok recenzije drugih kupaca imaju izraženiju ulogu jer prenose iskustva osoba koje su parfem već koristile. U tom smislu recenzije se pokazuju važnijim osloncem pri smanjenju nesigurnosti od samog opisa mirisa. Doprinos rada je u tome što online kupnju parfema promatra kroz povezanost percipiranog rizika, iskustvene i osjetilne prirode proizvoda te informacijskih elemenata. Rezultati pokazuju da digitalno oglašavanje parfema ne bi trebalo ostati na vizualnoj privlačnosti, popustima ili općim promotivnim porukama, nego treba oblikovati informacijsko okruženje koje kupcu pomaže da realnije procijeni proizvod koji ne može prethodno isprobati. Buduća istraživanja mogla bi uključiti veći i raznolikiji uzorak, stvarne podatke o kupovnom ponašanju te detaljnije ispitati koje vrste recenzija, opisa mirisa ili personaliziranih preporuka najučinkovitije smanjuju percipirani rizik. Informacijski elementi u online kupnji parfema imaju važnu, ali ograničenu ulogu. Ne mogu zamijeniti iskustvo isprobavanja, ali može pomoći potrošaču da jasnije procijeni proizvod i odluku o kupnji donese s više sigurnosti. Upravo u tome leži prostor za učinkovitije digitalno oglašavanje parfema: ne u pokušaju da se fizičko iskustvo potpuno nadomjesti, nego u smanjenju rizika koji potrošač preuzima pri online kupnji.

REFERENCE

1. Argyanti, T., Sabil Hussein, A. i Oktaviani, F. H. (2025). *Online blind buying of local perfume: Reducing uncertainty through digital cues*. Komunikator, 17(2), 167-180. <https://doi.org/10.18196/jkm.v17i2.27086>
2. Barbosa, B., Mahdavi, M., Oliveira, Z. i Chkoniya, V. (2021). *Buying perfume in the digital age: A study on e-shoppers' perceptions and typologies*. Asian Journal of Business and Accounting, 14(1), 1-32. <https://doi.org/10.22452/ajba.vol14no1.1>
3. Beg, I. (2020). *Intermedijalne prakse osjetilnog marketinga* [završni rad]. Filozofski fakultet Sveučilišta u Rijeci.
4. Cheung, C. M. K. i Thadani, D. R. (2012). *The impact of electronic word-of-mouth communication: A literature analysis and integrative model*. Decision Support Systems, 54(1), 461-470. <https://doi.org/10.1016/j.dss.2012.06.008>
5. Chevalier, J. A. i Mayzlin, D. (2006). *The effect of word of mouth on sales: Online book reviews*. Journal of Marketing Research, 43(3), 345-354. <https://doi.org/10.1509/jmkr.43.3.345>
6. Čarapina Zovko, I. i Đinkić, I. (2022). *Efekti mirisa i boje proizvoda na atraktivnost kupnje*. South Eastern European Journal of Communication, 4(1), 31-43. <https://doi.org/10.47960/2712-0457.2022.1.4.31>
7. Featherman, M. S. i Pavlou, P. A. (2003). *Predicting e-services adoption: A perceived risk facets perspective*. International Journal of Human-Computer Studies, 59(4), 451-474. [https://doi.org/10.1016/S1071-5819\(03\)00111-3](https://doi.org/10.1016/S1071-5819(03)00111-3)
8. Forsythe, S. M. i Shi, B. (2003). *Consumer patronage and risk perceptions in Internet shopping*. Journal of Business Research, 56(11), 867-875. [https://doi.org/10.1016/S0148-2963\(01\)00273-9](https://doi.org/10.1016/S0148-2963(01)00273-9)
9. Hennig-Thurau, T., Gwinner, K. P., Walsh, G. i Gremler, D. D. (2004). *Electronic word-of-mouth via consumer-opinion platforms: What motivates consumers to articulate themselves on the Internet?* Journal of Interactive Marketing, 18(1), 38-52. <https://doi.org/10.1002/dir.10073>
10. Huang, P., Lurie, N. H. i Mitra, S. (2009). *Searching for experience on the Web: An empirical examination of consumer behavior for search and experience goods*. Journal of Marketing, 73(2), 55-69. <https://doi.org/10.1509/jmkg.73.2.55>
11. Krishna, A. (2012). *An integrative review of sensory marketing: Engaging the senses to affect perception, judgment and behavior*. Journal of Consumer Psychology, 22(3), 332-351. <https://doi.org/10.1016/j.jcps.2011.08.003>
12. Mađarić, M. (1999). *Svijet parfema*. Zagreb: Golden marketing.
13. Nelson, P. (1970). *Information and consumer behavior*. Journal of Political Economy, 78(2), 311-329. <https://doi.org/10.1086/259630>
14. Paula, B. A. S. de, Farias, M. L., Farias, S. A. de i Silva, I. M. M. e. (2020). *In the purchase's essence: Sensory and symbolic elements in the descriptions of perfume sales over the Internet*. Consumer Behavior Review, 4(3), 217-228. <https://doi.org/10.51359/2526-7884.2020.244525>
15. 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), 101-134. <https://doi.org/10.1080/10864415.2003.11044275>
16. Peck, J. i Childers, T. L. (2003). *To have and to hold: The influence of haptic information on product judgments*. Journal of Marketing, 67(2), 35-48. <https://doi.org/10.1509/jmkg.67.2.35.18612>

DIGITALNI MARKETING LOKALNE HRANE I RURALNOG TURIZMA: UTJECAJ AUTENTIČNOSTI, SLJEDIVOSTI I KORISNIČKOG ISKUSTVA NA NAMJERU KUPNJE

DAMIR MIHANOVIĆ

Veleučilište „Marko Marulić” u Kninu
Kralja Petra Krešimira IV 30, 22300 Knin, Hrvatska
damir.mihanovic@veleknin.hr

ANITA PAMUKOVIĆ

Veleučilište „Marko Marulić” u Kninu
Kralja Petra Krešimira IV 30, 22300 Knin, Hrvatska
anita.pamukovic@veleknin.hr

EMILIJA FRIGANOVIĆ

Veleučilište „Marko Marulić” u Kninu
Kralja Petra Krešimira IV 30, 22300 Knin, Hrvatska
emilija.friganovic@veleknin.hr

SAŽETAK

Digitalni kanali omogućuju malim proizvođačima hrane i pružateljima usluga ruralnog turizma izravan pristup tržištu, ali istodobno povećavaju potrebu za dokazivanjem vjerodostojnosti ponude. Cilj rada jest konceptualno objasniti kako autentičnost, sljedivost i digitalno korisničko iskustvo djeluju na percipiranu vrijednost, percipirani rizik, povjerenje i namjeru kupnje, rezervacije i preporuke lokalne hrane i usluga ruralnog turizma. Rad se temelji na strukturiranom integrativnom pregledu literature iz digitalnog marketinga, ponašanja potrošača, turizma, kratkih lanaca opskrbe i sljedivosti hrane. Istraživanje je provedeno od 9. lipnja 2026. do 16. lipnja 2026. u bazama Crossref, OpenAlex i Google Scholar, s dodatnim unatragnim pretraživanjem referenci. U operativnom korpusu identificirano je 240 zapisa iz Crossrefa i OpenAlexa, nakon uklanjanja duplikata 218 jedinstvenih zapisa, od kojih je 36 izvora uključeno u završnu konceptualnu sintezu uz temeljne teorijske izvore.

Predlaže se prošireni model A-S-K-P-N, prema kojem autentičnost stvara simboličku i iskustvenu vrijednost, sljedivost smanjuje percipirani rizik, digitalno korisničko iskustvo olakšava transakciju i moderira učinak povjerenja na ponašajnu namjeru, a povjerenje povezuje dokazanu vrijednost ponude s kupnjom, rezervacijom i preporukom. Doprinos rada nije u tvrdnji da pojedini odnosi postoje izolirano, nego u objašnjenju kako se u ponudi lokalne hrane i ruralnog turizma emocionalni dokaz autentičnosti, informacijski dokaz podrijetla i funkcionalna jednostavnost digitalnog puta moraju promatrati zajedno. Zaključuje se da konkurentska prednost lokalne hrane i ruralnog turizma ne proizlazi iz same tvrdnje o lokalnosti, nego iz sposobnosti da se lokalnost jasno definira, vjerodostojno dokaže i pretvori u jednostavan korisnički put.

KLJUČNE RIJEČI: digitalni marketing, lokalna hrana, ruralni turizam, autentičnost, sljedivost, povjerenje, namjera kupnje

1. UVOD

Digitalizacija je promijenila način na koji potrošači otkrivaju, procjenjuju i kupuju lokalnu hranu te biraju ruralna turistička iskustva. Internetske tražilice, društvene mreže, digitalne karte, platforme za rezervaciju, internetske trgovine i recenzije omogućuju malim proizvođačima i ruralnim domaćinstvima vidljivost koja je donedavno bila dostupna pretežito većim tržišnim subjektima (Chaffey & Ellis-Chadwick, 2019; Kotler et al., 2021; Xiang et al., 2015; Zeng & Gerritsen, 2014). Istodobno se odluka o kupnji sve češće donosi bez fizičkog kontakta s proizvodom, proizvođačem ili destinacijom.

Lokalna hrana i ruralni turizam imaju zajedničku tržišnu osnovu: vrijednost proizlazi iz povezanosti s mjestom, ljudima, znanjem i načinom proizvodnje. Potrošač ne kupuje samo proizvod, smještaj ili obrok, nego očekuje susret s lokalnom kulturom, krajolikom i društvenim identitetom prostora. Istraživanja pokazuju da lokalna gastronomija može ojačati identitet destinacije, zadovoljstvo posjetitelja i održivost ruralnih područja (Bessière, 1998; Björk & Kauppinen-Räsänen, 2016; Ellis et al., 2018; Everett & Aitchison, 2008; Sims, 2009). Novija istraživanja dodatno upozoravaju da digitalne platforme mogu istodobno povećati dostupnost lokalnih proizvoda i oslabiti njihovu lokalnu posebnost ako potrošač ne može razlikovati platformsku praktičnost od stvarne lokalnosti (Viciunaite, 2023; Fuentes, 2024).

Problem nastaje kada oznake „lokalno”, „domaće”, „tradicionalno” i „autentično” ostanu samo marketinške tvrdnje. U digitalnom okruženju fizički znakovi vjerodostojnosti zamjenjuju se fotografijama, opisima, certifikatima, kartama podrijetla, profilima proizvođača, recenzijama i podacima o sljedivosti. Povjerenje zato postaje središnji resurs digitalne razmjene. Dodatnu složenost stvaraju generativna umjetna inteligencija, automatizirani sadržaj i platforme koje mogu povećati učinkovitost komunikacije, ali i otvoriti pitanje sintetičke autentičnosti, vjerodostojnosti sadržaja i odgovornosti za informaciju (Dogru et al., 2023; Mogaji et al., 2024).

Istraživačka praznina koju ovaj rad obrađuje nalazi se na sjecištu triju područja. Prvo, literatura o gastronomskom i ruralnom turizmu snažno objašnjava autentičnost i iskustvenu vrijednost, ali rjeđe uključuje provjerljivost podrijetla kao informacijski mehanizam povjerenja. Drugo, literatura o sljedivosti hrane sve više objašnjava transparentnost i tehnologije poput blockchaina, ali često ostaje odvojena od emocionalne i turističke vrijednosti lokalne hrane. Treće, literatura o digitalnom korisničkom iskustvu objašnjava konverziju i namjeru kupnje, ali je često generička i nedovoljno prilagođena malim proizvođačima, ruralnim domaćinstvima i destinacijskim organizacijama.

Cilj rada jest razviti konceptualni okvir koji povezuje autentičnost, sljedivost, digitalno korisničko iskustvo, percipiranu vrijednost, percipirani rizik, povjerenje i namjeru kupnje u kontekstu lokalne hrane i ruralnog turizma. Rad odgovara na četiri pitanja: kako autentičnost utječe na percipiranu vrijednost; kako sljedivost smanjuje rizik i povećava povjerenje; koje značajke digitalnog iskustva pretvaraju interes u kupnju, rezervaciju i preporuku; te pod kojim uvjetima navedeni odnosi mogu oslabjeti ili promijeniti smjer.

2. TEORIJSKI OKVIR

2.1. LOKALNA HRANA I RURALNI TURIZAM KAO POVEZANE, ALI RAZLIČITE PONUDE

Lokalna hrana i ruralni turizam često se tržišno povezuju, ali nisu istoznačni fenomeni. Kod prehrambenog proizvoda potrošač procjenjuje podrijetlo, sigurnost, okus, cijenu, certifikate, način dostave i mogućnost ponovne kupnje. Kod turističke usluge procjenjuje iskustvo koje je neopipljivo prije konzumacije, vremenski ograničeno, ovisno o domaćinu, kapacitetu i ukupnoj dramaturgiji boravka. Stoga se isti konstrukti ne moraju ponašati jednako u oba konteksta.

U lokalnoj hrani sljedivost može imati neposrednu funkciju smanjenja sigurnosnog i informacijskog rizika. U ruralnom turizmu ista informacija postaje dio priče o mjestu, domaćinu i iskustvu. Primjerice, podatak o sorti grožđa ili načinu prerade može biti dokaz podrijetla proizvoda, ali i dio turističke interpretacije. Upravo ta dvostruka uloga čini područje lokalne hrane i ruralnog turizma teorijski zanimljivim: isti podatak može istodobno biti operativni dokaz, marketinški sadržaj i iskustveni element.

2.2. AUTENTIČNOST I PERCIPIRANA VRIJEDNOST

Autentičnost je složen konstrukt. U turizmu može označavati izvornost objekta ili prakse, društveno oblikovanu predodžbu vjerodostojnosti te osobni osjećaj stvarnog i smislenog iskustva (Wang, 1999). Kod lokalne hrane potrošač autentičnost povezuje s podrijetlom sirovine, tradicionalnim receptom, malim opsegom proizvodnje, izravnim kontaktom s proizvođačem ili kulturnom pričom proizvoda.

Hrana može djelovati kao „jestivi identitet” destinacije jer povezuje krajolik, proizvodnju, običaje i društvena sjećanja (Bessière, 1998; Richards, 2012). Kada je uključena u ruralni smještaj, kušaonicu, radionicu ili posjet gospodarstvu, njezina vrijednost raste kroz iskustveni kontekst. Novija istraživanja o baštini hrane i potrošačkoj kulturi pokazuju da autentičnost nije samo svojstvo proizvoda, nego i pregovarana percepcija koja se oblikuje kroz kulturne narative, društvene norme i tržišnu prezentaciju (Shahrin & Hussin, 2023). Zato autentičnost može povećati percipiranu vrijednost samo ako je potrošač doživljava kao relevantnu i vjerodostojnu.

2.3. SLJEDIVOST, TRANSPARENTNOST I POVJERENJE

Sljedivost hrane obuhvaća mogućnost praćenja proizvoda, sirovina i informacija kroz faze proizvodnje, prerade i distribucije. Za potrošača ona ima komunikacijsku vrijednost jer smanjuje informacijsku asimetriju i percipirani rizik (Golan et al., 2004; Giraud & Halawany, 2006). Digitalne oznake, QR kodovi i baze podataka mogu kupcu omogućiti pristup informacijama o proizvođaču, području proizvodnje, seriji, certifikatu ili načinu prerade.

Ipak, tehnologija sama po sebi ne jamči istinitost podatka pri unosu (Galvez et al., 2018; Kamilaris et al., 2019). Novija istraživanja o blockchain sljedivosti pokazuju da učinak na namjeru kupnje ovisi o povjerenju, razumljivosti informacije, ekspertizi potrošača i percepciji koristi (Mazzù et al., 2022; Wang & Scrimgeour, 2022; Li et al., 2023; Tao & Chao, 2024). Drugim riječima, sljedivost nije samo tehnički sustav nego i komunikacijski aranžman. Previše tehničkih podataka može povećati kognitivno opterećenje, dok premalo podataka ostavlja tvrdnju o lokalnosti bez dokaza.

2.4. DIGITALNO KORISNIČKO ISKUSTVO I NAMJERA PONAŠANJA

Korisničko iskustvo obuhvaća kognitivne, emocionalne, društvene i ponašajne reakcije tijekom cijelog odnosa s ponudom (Lemon & Verhoef, 2016). U digitalnom marketingu korisnički put uključuje otkrivanje, informiranje, usporedbu, kupnju ili rezervaciju, korištenje i naknadnu komunikaciju. Mobilna prilagođenost, brzina učitavanja, razumljiv sadržaj, jasna cijena, dostupnost termina, sigurno plaćanje i jednostavan kontakt smanjuju napor korisnika. Model prihvaćanja tehnologije naglašava percipiranu korisnost i jednostavnost uporabe (Davis, 1989), dok istraživanja internetske kupnje ističu povjerenje i percipirani rizik (Gefen et al., 2003; Pavlou, 2003).

U kontekstu lokalne hrane i ruralnog turizma digitalno iskustvo ima dvostruku ulogu. Prvo, ono djeluje kao transakcijski mehanizam jer omogućuje pretvaranje interesa u narudžbu, rezervaciju ili upit. Drugo, ono moderira odnos između povjerenja i namjere ponašanja: čak i kada korisnik vjeruje ponudi, loše sučelje, nejasna cijena ili komplicirana rezervacija mogu prekinuti korisnički put. Digitalno iskustvo stoga nije dodatak autentičnosti, nego uvjet njezine tržišne realizacije. U višekanalnom okruženju korisnik često prelazi između društvenih mreža, tražilica, digitalnih karata, platformi i izravnog kontakta, pa se iskustvo ne smije promatrati samo kao web-stranica, nego kao povezani korisnički put (Verhoef et al., 2015). Novija istraživanja o preferencijama za lokalne karakteristike hrane u aplikacijama za kupnju dodatno potvrđuju da digitalni kontekst mijenja način vrednovanja lokalnosti (Van Parys et al., 2026). Recenzije i korisnički sadržaj djeluju kao društveni dokaz, ali mogu biti korisni samo ako su vjerodostojni i ako se reputacijom aktivno upravlja (Hennig-Thurau et al., 2004; Filieri & McLeay, 2014).

3. METODOLOGIJA

Rad je oblikovan kao strukturirani integrativni, odnosno konceptualni pregled literature. Takav pristup primjeren je kada istraživački problem obuhvaća više disciplina i kada je cilj razviti teorijski okvir, a ne provesti metaanalizu učinaka (Snyder, 2019; Torraco, 2005). Budući da rad predlaže konceptualni model, oslanja se i na preporuke za oblikovanje konceptualnih članaka (Jaakkola, 2020).

Istraživanje je provedeno od 9. lipnja 2026. do 16. lipnja 2026. u bazama Crossref, OpenAlex i Google Scholar. Crossref i OpenAlex korišteni su zbog mogućnosti provjere DOI zapisa i reproduktivnog dohvaćanja bibliografskih podataka, dok je Google Scholar korišten kao dopunski alat za prepoznavanje relevantnih interdisciplinarnih i često citiranih izvora. Upotrijebljene su kombinacije pojmova prikazane u Tablici 1. Pretraživanje se usredotočilo na razdoblje 2022.–2026. radi aktualizacije digitalnih i platformskih promjena, ali su u sintezu uključeni i temeljni izvori prije 2022. kada su nužni za teorijsko utemeljenje konstrukata.

Kriteriji uključivanja bili su: rad mora obrađivati najmanje jedan od ključnih konstrukata modela; mora biti znanstveni ili relevantan teorijski izvor; mora biti primjenjiv na lokalnu hranu, ruralni turizam, digitalno korisničko iskustvo, sljedivost, povjerenje ili namjeru kupnje; te mora pridonositi objašnjenju odnosa među konstruktima. Isključeni su radovi koji su se bavili isključivo tehničkom arhitekturom sljedivosti bez potrošačke ili marketinške dimenzije, općim digitalnim marketingom bez relevantnosti za hranu ili turizam, te radovi bez jasne metodološke ili teorijske vrijednosti za cilj rada.

U operativnom pretraživanju Crossrefa i OpenAlexa identificirano je 240 zapisa, od čega 218 jedinstvenih nakon uklanjanja duplikata prema DOI oznaci ili naslovu. Naslovi i sažeci pregledani su prema kriterijima uključivanja. U završnu sintezu uključeno je 36 izvora: 21 iz ranijeg teorijskog korpusa i 15 novijih izvora iz razdoblja 2022.–2026. Kodiranje je provedeno prema šest kategorija: znakovi autentičnosti, informacije o podrijetlu i sljedivosti, percipirana vrijednost, percipirani rizik i povjerenje, značajke digitalnog korisničkog iskustva te namjera kupnje, rezervacije ili preporuke.

Sinteza je provedena u tri koraka. U prvom su koraku identificirane teorijske uloge pojedinih konstrukata. U drugom su koraku izdvojeni mehanizmi koji objašnjavaju zašto bi konstrukti mogli djelovati na povjerenje i namjeru ponašanja. U trećem su koraku uspoređeni konteksti lokalne hrane i ruralnog turizma kako bi se utvrdilo koji su odnosi zajednički, a koji ovise o tipu ponude. Budući da rad nije sustavni pregled prema PRISMA standardu, rezultati se ne tumače kao iscrpna evidencija svih nalaza, nego kao transparentna konceptualna sinteza dovoljno relevantnih izvora.

Tablica 1. Strategija pretraživanja i kriteriji uključivanja

Element	Opis
Baze	Crossref, OpenAlex i Google Scholar; dodatno unatragno pretraživanje referenci.
Datum pretraživanja	od 9. lipnja 2026. do 16. lipnja 2026.
Pojmovi	local food rural tourism authenticity; food traceability consumer trust purchase intention; digital customer experience purchase intention food tourism; alternative food networks digital platforms local food; generative artificial intelligence hospitality tourism marketing trust; rural tourism digital marketing local food.
Razdoblje	Prioritetno 2022.–2026.; raniji radovi uključeni kada predstavljaju temeljne teorijske izvore.
Kriteriji uključivanja	Relevantnost za autentičnost, sljedivost, digitalno iskustvo, povjerenje, lokalnu hranu, ruralni turizam ili namjeru ponašanja.
Kriteriji isključivanja	Isključivo tehnički radovi bez potrošačke ili marketinške dimenzije; opći digitalni marketing bez veze s predmetom rada; izvori bez jasnog doprinosa modelu.
Rezultat	240 početnih zapisa u Crossrefu i OpenAlexu; 218 jedinstvenih zapisa nakon uklanjanja duplikata; 36 izvora uključeno u završnu sintezu.

Tablica 2. Odabrani noviji izvori i doprinos modelu

Izvor	Kontekst	Ključni doprinos modelu
Viciunaite (2023)	Digitalne platforme i lokalna hrana	Razlikuje vrijednost platformskih atributa i atributa lokalnosti.
Fuentes (2024)	Etička potrošnja i digitalne food platforme	Pokazuje da digitalna konfiguracija potrošača može oslabiti stvarnu etičku/lokalnu praksu.
Wang & Scrimgeour (2022)	Blockchain sljedivost hrane	Učinak sljedivosti ovisi o ekspertizi potrošača i karakteristikama inovacije.
Li et al. (2023)	Blockchain i organska hrana	Tehnologija može ojačati ili oslabiti vezu povjerenja i usvajanja ovisno o percepciji korisnika.

Tao & Chao (2024)	Online kupnja organskih proizvoda	Sljedivost utječe na online namjeru kupnje preko povjerenja i informacijske vrijednosti.
Dogru et al. (2023)	Generativna AI u turizmu	Otvora pitanje novih digitalnih posrednika, automatiziranog sadržaja i povjerenja u turizmu.
Mogaji et al. (2024)	TAM i generativna AI	Dopunjuje korisničko iskustvo novim izazovima prihvatanja tehnologije.
Grinberga-Zalite et al. (2025)	Greenwashing u lokalnim agri-food sustavima i ruralnom turizmu	Naglašava rizik deklarativne lokalnosti i potrebu za provjerljivim dokazima.

4. REZULTATI SINTEZE I MODEL A-S-K-P-N

Sinteza literature upućuje na četiri ključna nalaza. Prvo, autentičnost privlači pozornost i povećava percipiranu vrijednost kada je vezana uz konkretno mjesto, osobu, proizvodni postupak ili kulturnu praksu. Fotografija proizvođača, kratka priča o gospodarstvu, prikaz krajolika i objašnjenje recepta mogu proizvod pretvoriti u značenjski bogatu ponudu. Međutim, autentičnost koja se komunicira samo estetikom lako postaje generična i može izazvati sumnju ako nije potkrijepljena dokazima.

Drugo, sljedivost marketinšku tvrdnju pretvara u provjerljivu informaciju. Podatak o proizvođaču, sirovini, certifikatu ili seriji može smanjiti percipirani rizik i ojačati povjerenje, posebno kada je prikazan jednostavno i korisnički razumljivo. Nalazi o blockchain sljedivosti pokazuju da tehnologija može povećati povjerenje, ali samo ako potrošač razumije što mu podatak govori i vjeruje instituciji ili subjektu koji podatak jamči (Wang & Scrimgeour, 2022; Li et al., 2023; Tao & Chao, 2024).

Treće, digitalno korisničko iskustvo određuje hoće li interes prijeći u kupnju. Potrošač može vjerovati priči o lokalnosti, ali odustati ako ne može pronaći cijenu, dostavu, uvjete rezervacije ili siguran način plaćanja. Zato digitalni marketing ne treba promatrati kao dekoraciju proizvoda, nego kao sustav dokazivanja i isporuke vrijednosti.

Četvrto, odnosi u modelu nisu bezuvjetno pozitivni. Viša autentičnost ne mora povećati kupnju ako je cijena previsoka, ako potrošač ne vrednuje lokalnost ili ako se autentičnost doživljava kao marketinška inscenacija. Sljedivost ne mora povećati povjerenje ako je prikazana nerazumljivo ili ako potrošač ne vjeruje izvoru podataka. Digitalno korisničko iskustvo ne može nadomjestiti lošu kvalitetu proizvoda ili usluge, ali može odlučiti hoće li se postojeće povjerenje pretvoriti u ponašanje.

4.1. ZNANSTVENA NOVOST MODELA


Predloženi model A-S-K-P-N ne tvrdi da su autentičnost, sljedivost, korisničko iskustvo, povjerenje i namjera kupnje novi konstrukti. Njegova novost nalazi se u integraciji triju mehanizama koji se u literaturi često analiziraju odvojeno: simboličko-iskustvenog mehanizma autentičnosti, informacijskog mehanizma sljedivosti i funkcionalno-transakcijskog mehanizma digitalnog korisničkog iskustva. U kontekstu lokalne hrane i ruralnog turizma ti se mehanizmi preklapaju jer ista ponuda istodobno mora biti kulturno uvjerljiva, informacijski provjerljiva i digitalno lako kupiva ili rezervabilna.

U odnosu na radove o food tourismu, model dodaje informacijsku komponentu sljedivosti i smanjenja rizika. U odnosu na literaturu o sljedivosti, naglašava da dokaz podrijetla treba biti pretvoren u razumljiv i emocionalno relevantan sadržaj. U odnosu na opće modele digitalnog iskustva, model je prilagođen malim proizvođačima hrane, ruralnim domaćinstvima i destinacijskim organizacijama. Doprinos je zato prvenstveno konfiguracijski: model objašnjava pod kojim uvjetima lokalnost prelazi iz identitetske tvrdnje u vjerodostojnu i transakcijski izvedivu tržišnu vrijednost.

Slika 1. Prošireni konceptualni model A-S-K-P-N

Pristup	Dominantni fokus	Ograničenje za predmet rada	Doprinos A-S-K-P-N
Food tourism i autentičnost	Iskustvo, identitet mjesta, gastronomija	Slabije uključuje provjerljive podatke o podrijetlu i sljedivosti.	Povezuje autentičnost s informacijskim dokazima i digitalnom transakcijom.
Sljedivost hrane	Sigurnost, podrijetlo, transparentnost, tehnologija	Često nedovoljno obrađuje emocionalnu i turističku vrijednost lokalnosti.	Sljedivost tumači kao dokaz koji mora biti razumljiv i iskustveno relevantan.
Digitalno korisničko iskustvo	Sučelje, korisnost, jednostavnost, konverzija	Generički modeli ne razlikuju lokalnu hranu i ruralni turizam.	Korisničko iskustvo postavlja kao moderator povjerenja i transakcijski mehanizam.
A-S-K-P-N	Autentičnost, sljedivost, korisničko iskustvo, povjerenje i namjera	Konceptualni model koji traži empirijsku provjeru.	Objašnjava kako lokalnost postaje tržišna vrijednost tek kada je doživljena, dokazana i lako dostupna.

Model razlikuje prediktore (A, S), posrednike (PV, R, P), moderatorsko-transakcijski učinak K i ishod N.



Izvor: Autori

4.2. PROPOZICIJE MODELA

Na temelju sinteze literature formuliraju se sljedeće propozicije:

P1: Percipirana autentičnost lokalne hrane i ruralnog turističkog iskustva pozitivno je povezana s percipiranom vrijednošću ponude, osobito kada je autentičnost vezana uz konkretno mjesto, osobu, praksu ili dokazivu lokalnu tradiciju.

P2: Percipirana sljedivost i transparentnost podrijetla negativno su povezane s percipiranim rizikom, a pozitivno s povjerenjem u ponuditelja.

P3: Percipirana vrijednost posreduje odnos između autentičnosti i povjerenja, jer autentičnost postaje tržišno relevantna tek kada korisnik u njoj prepozna funkcionalnu, emocionalnu ili simboličku korist.

P4: Povjerenje posreduje odnos između smanjenog rizika i namjere kupnje, rezervacije ili preporuke.

P5: Kvaliteta digitalnog korisničkog iskustva pozitivno je povezana s namjerom ponašanja i dodatno moderira odnos između povjerenja i namjere ponašanja. Učinak povjerenja na namjeru bit će slabiji ako je digitalni put nejasan, spor ili transakcijski nepouzdan.

P6: Tip ponude moderira relativnu važnost pojedinih konstrukata. Kod prehrambenih proizvoda veća je težina sigurnosti, podrijetla, cijene i ponovne kupnje, dok je kod ruralnog turizma veća težina iskustvene kvalitete, dostupnosti termina, reputacije domaćina i nemogućnosti potpune procjene prije konzumacije.

Tablica 3. Propozicije modela A-S-K-P-N

Oznaka	Odnos	Teorijska logika
P1	Autentičnost → percipirana vrijednost	Autentičnost povećava simboličku i iskustvenu vrijednost kada je konkretna i vjerodostojna.
P2	Sljedivost → niži rizik i veće povjerenje	Informacije o podrijetlu smanjuju informacijsku asimetriju.
P3	Autentičnost → vrijednost → povjerenje	Autentičnost djeluje preko koristi koju korisnik prepoznaje.
P4	Niži rizik → povjerenje → namjera	Povjerenje povezuje dokaz i ponašajnu namjeru.
P5	Korisničko iskustvo moderira povjerenje → namjera	Povjerenje se teže pretvara u kupnju ako je digitalni put loš.
P6	Tip ponude moderira odnose	Hrana i turizam razlikuju se po riziku, opipljivosti, vremenu potrošnje i ulozi domaćina.

5. RASPRAVA

Rezultati upućuju na potrebu povezivanja marketinškog i operativnog pogleda. Mali proizvođač može imati stvarno lokalnu i kvalitetnu hranu, ali ako podrijetlo nije vidljivo, tržište tu vrijednost ne može prepoznati. Obrnuto, uspješan digitalni sadržaj može kratkoročno privući kupce, ali nedosljedna kvaliteta i netočne tvrdnje brzo narušavaju reputaciju. To je posebno važno u uvjetima digitalne preobilnosti informacija i rasta sintetičkog sadržaja, gdje potrošač sve teže razlikuje autentičan sadržaj od marketinški generirane slike.

Za ruralne destinacije važna je zajednička infrastruktura. Destinacijske organizacije, lokalne akcijske grupe i udruženja proizvođača mogu osigurati zajedničke standarde podataka,

edukaciju, digitalne karte i platforme. Ipak, agregator ne smije ostati samo katalog bez ažurnih cijena, dostupnosti i mogućnosti transakcije. Ako korisnik nakon inspiracije ne može jednostavno kupiti proizvod, rezervirati iskustvo ili dobiti pouzdanu informaciju, digitalna vidljivost ne prelazi u tržišni rezultat.

Model također upozorava na granične uvjete. Kod cjenovno osjetljivih potrošača lokalnost i autentičnost mogu biti sekundarne u odnosu na cijenu i praktičnost. Kod digitalno manje pismenih korisnika opsežne informacije o sljedivosti mogu smanjiti jasnoću umjesto povećati povjerenje. Kod visokovrijednih turističkih iskustava recenzije i reputacija domaćina mogu imati snažniji učinak od formalnih podataka o podrijetlu proizvoda. Kod platformskih posrednika korisnik može više vjerovati platformi nego lokalnom proizvođaču, što mijenja način izgradnje povjerenja.

Poseban izazov predstavlja značenje pojma „lokalno”. Proizvod može biti proizveden u destinaciji od uvoznih sirovina, sadržavati lokalnu sirovinu prerađenu drugdje ili se prodavati pod nazivom mjesta bez stvarne gospodarske veze s lokalnom zajednicom. Transparentno objašnjenje lanca uvjerljivije je od pojednostavljene tvrdnje koja se naknadno može pokazati netočnom. Novija istraživanja o greenwashingu u lokalnim agri-food sustavima i ruralnom turizmu potvrđuju da potrošači sve više prepoznaju razliku između vjerodostojne održivosti i marketinškog ukrašavanja (Grinberga-Zalite et al., 2025).

6. PRAKTIČNE IMPLIKACIJE

Za proizvođače lokalne hrane prioritet treba biti minimalno vjerodostojan digitalni proizvod: mobilno prilagođena stranica, jasne cijene, dostupnost, podaci o podrijetlu, alergeni, način dostave i jednostavan kontakt. QR kod na pakiranju može voditi na stranicu proizvođača ili serije, ali sadržaj mora biti ažuran i razumljiv nestručnom korisniku.

Za ruralna turistička domaćinstva preporučuje se povezivanje hrane s rasporedom iskustva: doručak s lokalnim proizvodima, posjet proizvođaču, radionica i mogućnost kupnje za ponijeti ili naknadne internetske narudžbe. Svaki element treba imati jasno trajanje, cijenu, broj sudionika i uvjete rezervacije.

Za destinacijske organizacije preporučuje se zajednički registar provjerenih proizvođača i iskustava, jedinstvena definicija tvrdnji o lokalnosti, povezivanje sadržaja s digitalnim kartama te analitika korisničkog puta. Uspjeh treba mjeriti brojem rezervacija, vrijednošću prodaje lokalnih proizvoda, ponovljenim kupnjama i preporukama, a ne samo posjetima web-stranici.

Za kreatore digitalnih platformi preporučuje se razlikovanje triju razina informacija: osnovne informacije vidljive odmah, dokazni podaci dostupni klikom ili QR kodom, te detaljni tehnički podaci dostupni korisnicima koji ih traže. Takav slojeviti prikaz smanjuje kognitivno opterećenje i istodobno čuva vjerodostojnost.

7. OGRANIČENJA I BUDUĆA ISTRAŽIVANJA

Ograničenje rada proizlazi iz konceptualnog pristupa i izostanka primarnih podataka. Predložene propozicije nisu empirijski testirane, pa se model treba promatrati kao teorijski okvir za buduća istraživanja, a ne kao potvrđeni kauzalni model. Dodatno, pregled literature

nije sustavni pregled prema PRISMA standardu, nego strukturirani integrativni pregled usmjeren na razvoj konceptualnog okvira.

Buduća istraživanja trebaju empirijski provjeriti relativnu snagu izravnih i neizravnih učinaka autentičnosti, sljedivosti i korisničkog iskustva na stvarnu kupnju, rezervaciju i ponovnu kupnju. Posebno su korisni eksperimentalni nacrti koji mogu usporediti različite razine informacija o sljedivosti, različite oblike komunikacije autentičnosti i različitu kvalitetu digitalnog sučelja. Također su potrebna istraživanja koja razlikuju lokalnu hranu i ruralni turizam kao povezane, ali tržišno i psihološki različite kategorije ponude.

8. ZAKLJUČAK

Digitalni marketing može povezati lokalnu hranu i ruralni turizam u prepoznatljivu tržišnu ponudu, ali njegova učinkovitost ovisi o usklađenosti obećanja, dokaza i izvedbe. Autentičnost privlači pozornost i stvara emocionalnu vrijednost; sljedivost pretvara tvrdnju u provjerljivu informaciju; korisničko iskustvo smanjuje napor i omogućuje kupnju; povjerenje povezuje sve elemente s namjerom kupnje, preporuke i ponovnog dolaska.

Glavni doprinos rada jest prošireni model A-S-K-P-N, koji pokazuje da lokalnost nije dovoljna konkurentska prednost ako nije jasno definirana, vjerodostojno dokazana i jednostavno dostupna kupcu. Najvrjednija digitalna priča nije ona koja najglasnije tvrdi da je proizvod autentičan, nego ona čije se obećanje može pratiti od objave i rezervacije do stvarnog okusa, susreta i ponovne kupnje.

IZJAVA O KORIŠTENJU GENERATIVNE UMJETNE INTELIGENCIJE

Autori izjavljuju da su digitalni alati za jezičnu, uredničku i bibliografsku podršku korišteni isključivo kao pomoć u oblikovanju teksta, provjeri dosljednosti i tehničkoj doradi rukopisa. Autori preuzimaju punu odgovornost za sadržaj, interpretacije, izvore i konačnu verziju rada.

IZJAVA O SUKOBU INTERESA

Autori izjavljuju da nemaju sukob interesa povezan s temom rada.

REFERENCE

1. Bessière, J. (1998). Local development and heritage: Traditional food and cuisine as tourist attractions in rural areas. *Sociologia Ruralis*, 38(1), 21-34. <https://doi.org/10.1111/1467-9523.00061>
2. Björk, P., & Kauppinen-Räsänen, H. (2016). Local food: A source for destination attraction. *International Journal of Contemporary Hospitality Management*, 28(1), 177-194. <https://doi.org/10.1108/IJCHM-05-2014-0214>
3. Chaffey, D., & Ellis-Chadwick, F. (2019). *Digital marketing: Strategy, implementation and practice* (7th ed.). Pearson.
4. Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319-340. <https://doi.org/10.2307/249008>

5. Dogru, T., Line, N., Mody, M., Hanks, L., Abbott, J. A., Acikgoz, F., Assaf, A. G., Bakir, S., Berbekova, A., Bilgihan, A., Dalton, A. N., Erkmén, E., Geronasso, M., Gomez, D., Graves, S., Iskender, A., Ivanov, S., Kizildag, M., Lee, M., Liu, L., Mandala, M., Mody, M., Ryu, K., Sharma, A., Suess, C., & Zhang, T. (2023). Generative artificial intelligence in the hospitality and tourism industry: Developing a framework for future research. *Journal of Hospitality & Tourism Research*, 49(2), 235-253.
<https://doi.org/10.1177/10963480231188663>
6. Ellis, A., Park, E., Kim, S., & Yeoman, I. (2018). What is food tourism? *Tourism Management*, 68, 250-263. <https://doi.org/10.1016/j.tourman.2018.03.025>
7. Everett, S., & Aitchison, C. (2008). The role of food tourism in sustaining regional identity. *Journal of Sustainable Tourism*, 16(2), 150-167.
<https://doi.org/10.2167/jost696.0>
8. Filieri, R., & McLeay, F. (2014). E-WOM and accommodation: An analysis of the factors that influence travelers' adoption of information from online reviews. *Journal of Travel Research*, 53(1), 44-57. <https://doi.org/10.1177/0047287513481274>
9. Fuentes, C. (2024). Configuring ethical food consumers: Understanding the failures of digital food platforms. *Journal of Cultural Economy*, 18(6), 925-943.
<https://doi.org/10.1080/17530350.2024.2336465>
10. Galvez, J. F., Mejuto, J. C., & Simal-Gandara, J. (2018). Future challenges on the use of blockchain for food traceability analysis. *TrAC Trends in Analytical Chemistry*, 107, 222-232. <https://doi.org/10.1016/j.trac.2018.08.011>
11. Gefen, D., Karahanna, E., & Straub, D. W. (2003). Trust and TAM in online shopping: An integrated model. *MIS Quarterly*, 27(1), 51-90. <https://doi.org/10.2307/30036519>
12. Giraud, G., & Halawany, R. (2006). Consumers' perception of food traceability in Europe. In I. Smith & A. Furness (Eds.), *Improving traceability in food processing and distribution* (pp. 24-43). Woodhead Publishing.
13. Golan, E., Krissoff, B., Kuchler, F., Calvin, L., Nelson, K., & Price, G. (2004). *Traceability in the U.S. food supply: Economic theory and industry studies*. U.S. Department of Agriculture.
14. Grinberga-Zalite, G., Furmanova, K., Zeverte-Rivza, S., Paula, L., & Rivza, B. (2025). Consumer perceptions of greenwashing in local agri-food systems and rural tourism. *Agriculture*, 15(19), 1997. <https://doi.org/10.3390/agriculture15191997>
15. Hennig-Thurau, T., Gwinner, K. P., Walsh, G., & Gremler, D. D. (2004). Electronic word-of-mouth via consumer-opinion platforms. *Journal of Interactive Marketing*, 18(1), 38-52. <https://doi.org/10.1002/dir.10073>
16. Jaakkola, E. (2020). Designing conceptual articles: Four approaches. *AMS Review*, 10(1-2), 18-26. <https://doi.org/10.1007/s13162-020-00161-0>
17. Kamlaris, A., Fonts, A., & Prenafeta-Boldú, F. X. (2019). The rise of blockchain technology in agriculture and food supply chains. *Trends in Food Science & Technology*, 91, 640-652. <https://doi.org/10.1016/j.tifs.2019.07.034>
18. Kotler, P., Kartajaya, H., & Setiawan, I. (2021). *Marketing 5.0: Technology for humanity*. Wiley.
19. Lemon, K. N., & Verhoef, P. C. (2016). Understanding customer experience throughout the customer journey. *Journal of Marketing*, 80(6), 69-96.
<https://doi.org/10.1509/jm.15.0420>
20. Li, Y., Liao, A., Li, L., Zhang, M., & Liu, Y. (2023). Reinforcing or weakening? The role of blockchain technology in the link between consumer trust and organic food adoption. *Journal of Business Research*, 164, 113999.
<https://doi.org/10.1016/j.jbusres.2023.113999>

21. Mazzù, M. F., Baccelloni, A., & Lavini, L. (2022). Injecting trust in consumer purchase intention through blockchain: Evidences from the food supply chain. *Italian Journal of Marketing*, 2022(4), 459-482. <https://doi.org/10.1007/s43039-022-00061-0>
22. Mogaji, E., Viglia, G., Srivastava, P., & Dwivedi, Y. K. (2024). Is it the end of the technology acceptance model in the era of generative artificial intelligence? *International Journal of Contemporary Hospitality Management*, 36(10), 3324-3339. <https://doi.org/10.1108/ijchm-08-2023-1271>
23. Pavlou, P. A. (2003). Consumer acceptance of electronic commerce. *International Journal of Electronic Commerce*, 7(3), 101-134. <https://doi.org/10.1080/10864415.2003.11044275>
24. Richards, G. (2012). Food and the tourism experience: Major findings and policy orientations. In D. Dodd (Ed.), *Food and the tourism experience* (pp. 13-46). OECD Publishing.
25. Shahrin, N., & Hussin, H. (2023). Negotiating food heritage authenticity in consumer culture. *Tourism and Hospitality Management*, 29(2), 27-37. <https://doi.org/10.20867/thm.29.2.3>
26. Sims, R. (2009). Food, place and authenticity: Local food and the sustainable tourism experience. *Journal of Sustainable Tourism*, 17(3), 321-336. <https://doi.org/10.1080/09669580802359293>
27. Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333-339. <https://doi.org/10.1016/j.jbusres.2019.07.039>
28. Tao, Z., & Chao, J. (2024). The impact of a blockchain-based food traceability system on the online purchase intention of organic agricultural products. *Innovative Food Science & Emerging Technologies*, 92, 103598. <https://doi.org/10.1016/j.ifset.2024.103598>
29. Torraco, R. J. (2005). Writing integrative literature reviews: Guidelines and examples. *Human Resource Development Review*, 4(3), 356-367. <https://doi.org/10.1177/1534484305278283>
30. Van Parys, E., Tran, D., Rahmani, D., Le Moal, F., Bray, J., Ronge, B., Tarcsi, A., Lesic, V., Michaud, M., Gellynck, X., Schouteten, J. J., & De Steur, H. (2026). Consumer preferences for local food characteristics in grocery shopping apps: A multi-country discrete choice experiment. *Electronic Commerce Research*. <https://doi.org/10.1007/s10660-026-10144-1>
31. Verhoef, P. C., Kannan, P. K., & Inman, J. J. (2015). From multi-channel retailing to omni-channel retailing. *Journal of Retailing*, 91(2), 174-181. <https://doi.org/10.1016/j.jretai.2015.02.005>
32. Viciunaite, V. (2023). Alternative food networks on digital platforms: Consumer preferences for platform versus local food attributes. *Journal of Rural Studies*, 100, 103017. <https://doi.org/10.1016/j.jrurstud.2023.103017>
33. Wang, N. (1999). Rethinking authenticity in tourism experience. *Annals of Tourism Research*, 26(2), 349-370. [https://doi.org/10.1016/S0160-7383\(98\)00103-0](https://doi.org/10.1016/S0160-7383(98)00103-0)
34. Wang, O., & Scrimgeour, F. (2022). Consumer adoption of blockchain food traceability: Effects of innovation-adoption characteristics, expertise in food traceability and blockchain technology, and segmentation. *British Food Journal*, 125(7), 2493-2513. <https://doi.org/10.1108/bfj-06-2022-0466>
35. Xiang, Z., Magnini, V. P., & Fesenmaier, D. R. (2015). Information technology and consumer behavior in travel and tourism. *Journal of Retailing and Consumer Services*, 22, 244-249. <https://doi.org/10.1016/j.jretconser.2014.08.005>
36. Zeng, B., & Gerritsen, R. (2014). What do we know about social media in tourism? *Tourism Management Perspectives*, 10, 27-36. <https://doi.org/10.1016/j.tmp.2014.01.001>

OD INOVACIJE DO REGULACIJE: BNPL I DIREKTIVA (EU) 2023/2225

TONI POŽEGA

Sveučilište Josipa Jurja Strossmayera u Osijeku
Doktorska škola
Doktorski interdisciplinarni studij Europski studiji
Trg Svetog Trojstva 3, 31000 Osijek, Hrvatska
pozegatoni5@gmail.com

NORA BALIĆ

Sveučilište Josipa Jurja Strossmayera u Osijeku
Doktorska škola
Doktorski interdisciplinarni studij Europski studiji
Trg Svetog Trojstva 3, 31000 Osijek, Hrvatska
norabalic09@gmail.com

SAŽETAK

Direktiva (EU) 2023/2225 proširuje područje primjene potrošačko-kreditne regulative na model „kupi sada, plati kasnije” (engl. buy now, pay later, BNPL) i ukida regulatornu arbitražu na kojoj je dosadašnji rast ove industrije počivao. Cilj je rada analizirati transmisijski mehanizam kojim navedena Direktiva utječe na poslovne modele BNPL pružatelja, s posebnim osvrtom na hrvatsko tržište. Primijenjen je kvalitativni teorijsko-analitički pristup koji integrira ekonomiju regulacije, ekonomiju potrošačkoga kredita i analizu fintech poslovnih modela. Rezultati pokazuju da Direktiva djeluje kroz četiri međusobno povezana mehanizma – proširenje područja primjene, obvezu procjene kreditne sposobnosti, standardizaciju predugovornih informacija i ograničenje marketinških komunikacija – koji se kumulativno preljevaju u rekonfiguraciju troškovne strukture, prihodovne logike i konkurentskih odnosa unutar industrije. Na temelju teorijske analize projicira se konsolidacija tržišta uz strukturnu prednost tradicionalnih banaka i BigTech aktera. U hrvatskome kontekstu, regulatorni okvir strukturira sektor u ranoj razvojnoj fazi, što stvara specifičnu dinamiku istodobnog regulatornog šoka i ulaska međunarodnih aktera na tržište.

KLJUČNE RIJEČI: potrošački kredit, fintech, transmisijski mehanizam, poslovni modeli, kreditna sposobnost, hrvatsko tržište

1. UVOD

Model odgođenog plaćanja „kupi sada, plati kasnije” (engl. *buy now, pay later*, dalje u tekstu: BNPL) tijekom posljednjeg je desetljeća prešao put od rubne platne pogodnosti do systemske komponente europske i globalne maloprodaje. Prema podacima Worldpaya (2025), BNPL je u 2024. godini činio približno 5 posto globalne vrijednosti elektroničke trgovine, odnosno oko 342 milijarde američkih dolara, što predstavlja rast od više od 15.000 posto u

odnosu na 2014. godinu. Komercijalne tržišne projekcije procjenjuju ukupni globalni obujam BNPL transakcija na oko 560 milijardi američkih dolara u 2025. godini, uz godišnju stopu rasta od 13,7 posto (Research and Markets, 2025), dok broj korisnika prema procjenama prelazi 380 milijuna (Juniper Research, 2025). Takav rast ne proizlazi isključivo iz tehnološke inovacije, već iz specifične arhitekture poslovnog modela u kojoj se kredit integrira izravno u proces naplate internetskih trgovaca i prezentira kao oblik fleksibilnog plaćanja, a ne kao kreditni proizvod. Vodeći pružatelji, među kojima se ističu Klarna, Affirm, Afterpay i PayPal, izgradili su tržišnu poziciju upravo na toj percepcijskoj i pravnoj razlici.

Izostanak regulatornog nadzora nad BNPL-om bio je strukturan: Direktiva 2008/48/EZ izuzimala je iz područja primjene kredite niskih iznosa i kratkih rokova dospelja bez ugovorenih kamata, čime je BNPL djelovao u prostoru regulatorne arbitraže¹ (Cherednychenko, 2024). Ekonomske posljedice te asimetrije mjerljive su: prema anketnim podacima, udio korisnika koji prijavljuju barem jedno zakašnjelo plaćanje u protekloj godini porastao je s 34 posto u 2024. na 41 posto u 2025. godini (LendingTree, 2025), dok regulatorni podaci istodobno pokazuju znatno niže stope formalnoga otpisa potraživanja, od približno 1,8 posto (Consumer Financial Protection Bureau [CFPB], 2025). Taj raskorak između učestaloga kašnjenja i niske stope otpisa upućuje na to da prihodovni model dijelom počiva na zateznim naknadama, a ne isključivo na proviziji koju plaćaju trgovci. Vidljiva korist za potrošača i prikriveni trošak strukturno su povezani unutar istoga poslovnog modela.

Donošenjem Direktive (EU) 2023/2225 Europskoga parlamenta i Vijeća o ugovorima o potrošačkim kreditima (dalje u tekstu: CCD2), koja stupa na primjenu 20. studenoga 2026., europski zakonodavac sustavno zatvara prostor regulatorne arbitraže. Materijalno područje primjene proširuje se na kredite bez kamata i kredite niskih iznosa, uvodeći obvezu procjene kreditne sposobnosti, standardizirane predugovorne informacije i ograničenja marketinških komunikacija (Direktiva (EU) 2023/2225). Time se BNPL pravno reklasificira kao oblik potrošačkoga kredita, što izravno dovodi u pitanje ekonomsku održivost dosadašnje arhitekture poslovnoga modela.

Polazeći od navedenoga, istraživačko pitanje rada glasi: na koji način i kroz koje transmisijske mehanizme Direktiva (EU) 2023/2225 utječe na poslovne modele pružatelja BNPL usluga te kakve implikacije taj utjecaj ima za hrvatsko tržište? Cilj rada jest sustavno razložiti regulatorne odredbe CCD2 i njihove ekonomske posljedice na razini troškovne strukture, prihodovne logike, marketinške komunikacije i konkurentске konfiguracije BNPL industrije, s posebnim osvrtom na specifičnosti hrvatskoga konteksta. Svrha rada je doprinijeti razumijevanju regulatorne transmisije između europskog pravnog okvira i ekonomske strukture digitalne potrošačko-kreditne industrije, što je analitičko područje koje u domaćoj literaturi do sada nije sustavno obrađeno.

Rad je strukturiran u sedam cjelina. Nakon ovog uvoda, u drugoj se cjelini razlaže teorijski okvir koji integrira ekonomiju regulacije, ekonomiju potrošačkoga kredita i strukturu BNPL poslovnoga modela. Treća cjelina prikazuje metodologiju. Četvrta cjelina analizira ključne odredbe CCD2 i izdvaja njihove transmisijske mehanizme. Peta cjelina razrađuje implikacije tih mehanizama na poslovne modele industrije. Šesta cjelina primjenjuje izvedeni okvir na hrvatski kontekst. Sedma cjelina sintetizira nalaze, identificira ograničenja istraživanja i predlaže pravce budućih istraživanja.

¹Pojam regulatorne arbitraže u kontekstu potrošačkoga kredita odnosi se na strukturiranje poslovne aktivnosti tako da se izbjegava primjena pravila koja bi se inače primjenjivala na funkcionalno ekvivalentni kreditni proizvod, koristeći klasifikacijske praznine u regulatornom okviru.

2. TEORIJSKI OKVIR

Analiza utjecaja Direktive (EU) 2023/2225 na poslovne modele BNPL pružatelja zahtijeva integraciju triju teorijskih pristupa. Prvi obuhvaća ekonomiju regulacije, koja objašnjava mehanizme i posljedice regulatorne intervencije na tržišnu strukturu; drugi se odnosi na ekonomiju potrošačkoga kredita, koja razmatra ponašanje potrošača u kontekstu kreditnih ugovora; treći se bavi strukturom BNPL-a kao tržišne inovacije unutar fintech ekosustava. Sintezom navedenih perspektiva uspostavlja se analitički okvir za razumijevanje transmisijskog mehanizma između regulatornih obveza i ekonomske strukture industrije.

2.1. EKONOMIJA REGULACIJE

Klasična teorija ekonomske regulacije, kako ju je definirao Stigler (1971), polazi od pretpostavke da regulacija nije neutralan instrument zaštite javnoga interesa, već posljedica artikuliranih interesa pojedinih tržišnih aktera. Prema tom shvaćanju, regulatorni akti redovito proizvode raspodjelne učinke koji povlašćuju određene skupine na štetu drugih. Posner (1974) tu argumentaciju proširuje na ekonomiju troška regulacije, pri čemu naglašava da svaka regulatorna intervencija stvara izravne troškove usklađenosti koji se prelijevaju u troškovnu strukturu reguliranih subjekata i, posredno, u cijenu finalnoga proizvoda. U kontekstu BNPL industrije, takav teorijski okvir omogućuje analizu CCD2 ne kao apstraktnog pravnog akta, već kao mehanizma koji generira mjerljive ekonomske posljedice na razini poslovnoga modela.

2.2. EKONOMIJA POTROŠAČKOGA KREDITA

Drugi teorijski stup proizlazi iz ekonomske analize potrošačkoga kredita. Bar-Gill (2012) u radu *Seduction by Contract* pokazuje da su kreditni ugovori sustavno dizajnirani na način koji eksploatira ograničenja potrošačke racionalnosti, posebice sklonost diskontiranju budućih troškova u korist neposrednih koristi. Slično tome, Agarwal i suradnici (2009) empirijski potvrđuju da financijske odluke pojedinaca pokazuju značajne deficite u različitim životnim fazama, što sugerira da potrošačka zaštita ne ovisi isključivo o transparentnosti informacija, već i o samoj strukturi proizvoda. Iz te perspektive, BNPL predstavlja paradigmatički primjer ugovora koji, formalno bez kamata, putem zateznih naknada i ponašajnih mehanizama generira ekonomski značajan trošak za dio korisničke baze.

2.3. STRUKTURA BNPL POSLOVNOGA MODELA

Treći teorijski stup odnosi se na razumijevanje BNPL-a kao specifičnoga tržišnog modela unutar fintech ekosustava. Philippon (2016) definira fintech kao inovaciju koja izaziva tradicionalne posrednike kroz nižu troškovnu strukturu i drugačiju arhitekturu odnosa s klijentima, dok Frost i suradnici (2019) ističu strukturnu transformaciju financijskoga posredovanja u kojoj BigTech i fintech akteri preuzimaju dio uloge banaka. Berg i suradnici (2020) dodatno analiziraju načine kojima fintech pružatelji koriste netradicionalne podatke za procjenu rizika, čime se djelomično supstituira klasična kreditna analiza. Cornelli i suradnici (2023) pokazuju da je rast fintech i BigTech kredita snažno povezan s nižom regulatornom strogošću, otvarajući prostor za nesrazmjeran rast izvan dosega tradicionalnoga nadzornog okvira i potencijalne sistemske rizike. Polazeći od navedenoga, BNPL se može pozicionirati kao tržišni model koji djeluje na razmeđu platne usluge i kreditnoga proizvoda, što ima izravne implikacije za način na koji ga novi regulatorni okvir tretira.

Sintezom ovih triju teorijskih perspektiva uspostavlja se analitički okvir prema kojem se učinci CCD2 ne razmatraju kao izolirane pravne posljedice, već kao integrirane ekonomske posljedice

na razini tržišne strukture, ponašanja potrošača i konfiguracije poslovnoga modela. Regulatorna se obveza time promatra kao trošak i kao ograničenje poslovnoga modela, a ne isključivo kao pravna norma.

3. METODOLOGIJA

Metodološki pristup ovoga rada temelji se na kvalitativnoj teorijsko-analitičkoj sintezi relevantne znanstvene literature, pravnih izvora i institucionalnih dokumenata, s ciljem rasvjetljavanja transmisijskog mehanizma između regulatornih obveza iz Direktive (EU) 2023/2225 i ekonomske strukture BNPL poslovnih modela. Odabir kvalitativnog pristupa metodološki je opravdan prirodom istraživačkog problema, budući da predmet analize obuhvaća pravne odredbe i ekonomske mehanizme koji zahtijevaju interpretativno i argumentacijsko razmatranje, a ne empirijsko testiranje hipoteza (Creswell, 2014).

Rad se oslanja na metodu pregleda i analize literature (engl. *desk research*), pri čemu je primijenjen integrativni pristup koji omogućuje povezivanje teorijskih, pravnih i empirijskih nalaza iz više disciplina (Snyder, 2019). Takav je pristup posebno prikladan kada je cilj izgraditi analitički okvir koji integrira regulatornu ekonomiju, ekonomiju potrošačkoga kredita i analizu poslovnih modela u jedinstvenu interpretaciju.

Izvori obuhvaćaju recenzirane znanstvene radove iz baza Google Scholar, SSRN i Hrčak, institucionalne dokumente Banke za međunarodne namire (BIS), Europskoga nadzornog tijela za bankarstvo (EBA), Europske središnje banke (ECB), Hrvatske agencije za nadzor financijskih usluga (HANFA) i Hrvatske narodne banke (HNB), te primarne pravne izvore iz EUR-Lexa, prvenstveno tekst Direktive (EU) 2023/2225 i ranijeg propisa Direktive 2008/48/EZ. Kriteriji odabira uključivali su tematsku relevantnost, recentnost, uz zadržavanje klasičnih teorijskih izvora trajne konceptualne vrijednosti i akademsku autoritativnost. Primjenom navedenih kriterija u konačnu je analizu uključen 31 izvor, što obuhvaća recenzirane znanstvene radove, institucionalne dokumente regulatornih i nadzornih tijela te primarne pravne izvore, dok su izvori koji nisu zadovoljili kriterij tematske relevantnosti, recentnosti ili autoritativnosti isključeni iz daljnjega razmatranja.

Analiza je provedena u tri faze. U prvoj fazi izvršena je identifikacija i sistematizacija relevantnih izvora prema unaprijed definiranim ključnim pojmovima („BNPL”, „buy now pay later”, „consumer credit directive”, „CCD2”, „regulatorna arbitraža”, „fintech regulation”). U drugoj fazi provedena je tematska klasifikacija prema trima teorijskim stupovima rada – ekonomiji regulacije, ekonomiji potrošačkoga kredita i strukturi BNPL poslovnoga modela. U trećoj fazi izvršena je komparativno-interpretativna sinteza kojom su uspostavljene analitičke poveznice između regulatornih odredbi i njihovih ekonomskih implikacija. Metodološki okvir oblikovan je u skladu s načelima znanstvene transparentnosti i logičke koherentnosti istraživačkoga postupka (Horvat, 2024).

4. CCD2: REGULATORNI OKVIR I TRANSMISIJSKI MEHANIZAM

Analiza utjecaja Direktive (EU) 2023/2225 na BNPL poslovne modele zahtijeva razlikovanje četiriju međusobno povezanih regulatornih mehanizama: proširenja područja primjene (čl. 2.), obveze procjene kreditne sposobnosti (čl. 18.), standardiziranih predugovornih informacija (čl. 10.–13.) i ograničenja marketinških komunikacija (čl. 7. i 8.).

Svaki od navedenih mehanizama generira specifičan transmisijski kanal koji prelijeva regulatornu obvezu u troškovnu strukturu ili u temeljne parametre poslovanja BNPL pružatelja.

4.1. PROŠIRENJE PODRUČJA PRIMJENE (ČL. 2.)

Najznačajnija strukturna promjena CCD2 u odnosu na prethodnu Direktivu 2008/48/EZ leži u širenju materijalnoga područja primjene. Cherednychenko (2024) ističe da se *informacijska paradigma* potrošačke zaštite, na kojoj je počivala CCD1, pokazala nedostatnom u uvjetima digitalnoga tržišta, gdje su izuzeća za male i kratkoročne kredite bez kamata omogućila BNPL pružateljima sustavno izbjegavanje kreditno-regulatornoga okvira. CCD2 odgovara na taj nedostatak ukidanjem donje granice od 200 eura, podizanjem gornje granice s 75 000 na 100 000 eura te eksplicitnim uključivanjem BNPL modela u definiciju ugovora o potrošačkom kreditu. Određene ublažene odredbe iz članka 2. stavka 8.² dopuštaju državama članicama da kredite ispod 200 eura, bez kamata i naknada, izuzmu od dijela informacijskih obveza, no obveza procjene kreditne sposobnosti vrijedi u punome obujmu. Člankom 2. stavkom 2. točkom (h) izvan područja primjene ostaje odgoda plaćanja koju trgovac odobrava sam, bez kamata i naknada i uz podmirenje u roku do 50 dana, odnosno 14 dana kada je riječ o trgovcima koji nisu mikro, mali ili srednji poduzetnici i ugovor sklapaju na daljinu, no to se izuzeće ne primjenjuje kada kredit nudi ili otkupljuje treća strana, što je upravo struktura tipičnoga BNPL aranžmana. Posljedica je jednoznačna: BNPL modeli u kojima financiranje osigurava treća strana pravno se kvalificiraju kao kreditni odnos, čime se uklanja strukturna osnova dosadašnje regulatorne arbitraže.

4.2. PROCJENA KREDITNE SPOSOBNOSTI (ČL. 18.)

Članak 18. uvodi obvezu temeljite procjene kreditne sposobnosti potrošača prije sklapanja svakoga ugovora. Europsko nadzorno tijelo za bankarstvo u svojim smjernicama o procjeni kreditne sposobnosti (EBA, 2020)³ razrađuje sadržaj te obveze, propisujući upotrebu potrebnih, relevantnih i razmjernih podataka o prihodima, izdacima i općoj financijskoj situaciji korisnika, uz mogućnost automatske obrade podataka i pravo potrošača na ljudsku intervenciju. Cherednychenko (2024) upozorava da takav prijelaz s informacijskoga modela na model aktivne procjene predstavlja jedan od najznačajnijih sadržajnih pomaka cijele Direktive. U BNPL kontekstu, gdje se odluka o odobravanju donosi u sekundama tijekom *checkout* procesa, takav zahtjev pretpostavlja uspostavu paralelne kreditne infrastrukture, pristup kreditnim registrima, *scoring* algoritme, dokumentacijski sustav i proceduru preispitivanja. Transmisijski mehanizam je dvostruk: rastu fiksni troškovi *compliance* sustava, dok dodatni korak u korisničkom putu narušava trenutačnost iskustva, koja je središnja sastavnica vrijednosne ponude BNPL proizvoda.

²Razmjeri tih izuzeća ovise o nacionalnoj transpoziciji, države članice mogu, ali ne moraju, koristiti diskreciju iz članka 2. stavka 8. CCD2. Procijenjeni utjecaj Direktive na BNPL tržište stoga može varirati među državama članicama, ovisno o opsegu primjene tih ublaženih odredbi. Hrvatski je zakonodavac tu diskreciju iskoristio u ograničenom opsegu, zadržavši olakšice za kredite manjih iznosa, beskamratne kredite i kredite otplate u roku od tri mjeseca uz zanemarive naknade.

³Smjernice EBA/GL/2020/06 donesene su prije CCD2, primarno za bankarsko kreditiranje. Načela razrade procjene kreditne sposobnosti, proporcionalnost podataka, pravo potrošača na ljudsku intervenciju i dokumentacijski standardi, institucionalno tvore podlogu koju CCD2 preuzima i proširuje na sve potrošačke kredite, uključujući BNPL.

4.3. PREDUGOVORNE INFORMACIJE I SECCI (ČL. 10.–13.)

Članci 10. do 13. uvode standardizirane predugovorne informacije, među kojima središnje mjesto zauzima obrazac *Standard European Consumer Credit Information* (SECCI)⁴, koji obuhvaća sve materijalne uvjete kredita, uključujući efektivnu kamatnu stopu, ukupni iznos koji potrošač plaća i posljedice neispunjavanja. Članak 12. propisuje obvezu davanja adekvatnih obrazloženja, dok članak 13. uvodi pravo potrošača na informaciju kada se ponuda temelji na automatskoj obradi osobnih podataka. Cherednychenko (2024) tumači razradu predugovornih obveza kao pokušaj zatvaranja praznine između formalne i stvarne informiranosti potrošača, koja je u digitalnome okruženju bila sustavno proširena. U BNPL kontekstu, takve obveze pretvaraju jednoslojni *checkout* u višeslojnu pravnu transakciju s eksplicitnim predugovornim koracima, od čega se može očekivati porast napuštanja košarice i pad stope dovršenja transakcija.

4.4. MARKETINŠKE KOMUNIKACIJE (ČL. 7. I 8.)

Članci 7. i 8. uspostavljaju regulatorni okvir za oglašavanje potrošačkih kredita. Članak 7. nalaže opće načelo poštene, jasne i neobmanjujuće komunikacije, dok članak 8. propisuje obvezni sadržaj svake oglasne poruke, među kojima i reprezentativni primjer s navodom efektivne kamatne stope te ukupnoga iznosa koji potrošač treba platiti. Direktiva izričito zabranjuje oglašavanje koje prikazuje kredit kao izvor obogaćivanja ili kao supstitut štednje, te ograničava ciljano oglašavanje prema ranjivim potrošačima. Za BNPL pružatelje, čiji su marketinški modeli povijesno bili izgrađeni oko poruka „0% kamate” i „plati u četiri rate bez troškova”, navedene odredbe znače fundamentalnu rekonfiguraciju komunikacijskoga registra, od signaliziranja besplatnosti prema standardiziranom prikazu kredita kao formalnoga financijskog proizvoda.

Komparativni pregled ključnih odredaba CCD1 i CCD2 prikazan je u Tablici 1. Nijedan od četiriju mehanizama ne djeluje izolirano: obveze se zbrajaju u istoj točki korisničkoga puta, na mjestu naplate.

Tablica 1. Komparacija CCD1 i CCD2, područje primjene i ključne odredbe

Odredba	CCD1 (Direktiva 2008/48/EZ)	CCD2 (Direktiva (EU) 2023/2225)
Donja granica iznosa	200 EUR	Ukinuta (BNPL eksplicitno uključen)
Gornja granica iznosa	75 000 EUR	100 000 EUR
Kredit bez kamata	Isključeni iz primjene	Uključeni (uz ograničena izuzeća iz čl. 2. st. 8.)
Procjena kreditne sposobnosti	Obvezna, bez detaljne razrade postupka	Obvezna „temeljita procjena” s razrađenim postupkom (čl. 18.)
Predugovorne informacije	SECCI obrazac, osnovni sadržaj	SECCI prošireni + adekvatna obrazloženja (čl. 12.) + obavijest o automatskoj obradi (čl. 13.)

⁴Obrazac SECCI uveden je već Direktivom 2008/48/EZ s ciljem harmonizacije predugovornih informacija na razini EU tržišta. CCD2 znatno proširuje njegov obvezni sadržaj, posebno u dijelu prikaza efektivne kamatne stope, ukupnog iznosa koji potrošač plaća i posljedica neispunjavanja.


Oglašavanje	Opće načelo	Specificiran sadržaj oglasa, reprezentativni primjer; zabrana prikazivanja kredita kao izvora obogaćivanja (čl. 7. i 8.)
-------------	-------------	--

Izvor: Prilagođeno prema Direktivi 2008/48/EZ i Direktivi (EU) 2023/2225 te Cherednychenko (2024).

5. IMPLIKACIJE ZA POSLOVNE MODELE BNPL INDUSTRIJE

CCD2 ne djeluje kao izolirana pravna intervencija, već kao kumulativni regulatorni šok koji istodobno mijenja troškovnu strukturu, prihodovne tokove, marketinšku ekonomiku i konkurentsku konfiguraciju industrije. Iako su navedene četiri dimenzije međusobno povezane, analitički ih je opravdano razmatrati kao zasebne kanale prijenosa, što je shematski prikazano na Prikazu 1.

Prikaz 1. Transmisijski mehanizam Direktive (EU) 2023/2225 na BNPL poslovne modele



Izvor: Autorska razrada

5.1. COMPLIANCE TROŠAK I KONSOLIDACIJA TRŽIŠTA

Usklađivanje s CCD2 zahtjevima podrazumijeva dvostruku troškovnu strukturu: fiksnu komponentu koja obuhvaća uspostavu kreditnoga sustava, *compliance* osoblja i pristupa kreditnim registrima, te varijabilnu komponentu koja se reflektira u svakoj pojedinačnoj transakciji kroz trošak procjene, dokumentacije i SECCI obrasca. Philippon (2016) u svojoj analizi fintech ekonomije pokazuje da regulatorni troškovi disproporcionalno opterećuju subjekte koji svoju konkurentsku prednost izvedu iz niske marginalne cijene transakcije, što izravno opisuje strukturni položaj BNPL fintech aktera. U istome smjeru, Cornelli i suradnici (2023) empirijski dokumentiraju da je rast fintech kredita u svjetskim ekonomijama izrazito povezan s nižom regulatornom strogošću, što sugerira da intenzivnija regulacija, kakvu uvodi CCD2, predvidljivo usporava taj rast i potiče konsolidaciju. Iz toga proizlazi predvidljiv proces

preustroja: smanjenje broja samostalnih BNPL aktera, intenziviranje akvizicija od strane tradicionalnih financijskih institucija te selektivno povlačenje pružatelja iz manje profitabilnih nacionalnih tržišta.

5.2. RESTRUKTURIRANJE PRIHODOVNE STRUKTURE

BNPL prihodovni model konvencionalno počiva na trima izvorima: proviziji koju plaćaju trgovci, zateznim naknadama i unakrsnoj prodaji povezanih financijskih proizvoda. CCD2 svaki od tih izvora pogađa na specifičan način. Di Maggio i suradnici (2022) u svojoj NBER analizi dokumentiraju da BNPL pristup povećava ukupnu razinu potrošnje i udio maloprodajne potrošnje, pri čemu dio te potrošnje, osobito kod likvidnosno ograničenih korisnika, rezultira prekoračenjima i zakašnjelim plaćanjima koja generiraju prihod od naknada. Uvođenjem obvezne procjene kreditne sposobnosti, dio korisnika koji bi pod prethodnim režimom bio izložen takvim neispunjavanjima izvan-sustavno se isključuje iz pristupa kreditu, što paradoksalno smanjuje prihod od zateznih naknada, premda poboljšava prosječnu kvalitetu portfelja. Stavins (2024) u empirijskoj analizi američkoga BNPL tržišta upozorava da je korištenje BNPL-a izraženije među financijski ranjivijim potrošačima, što jača argument za regulatornu intervenciju. Istodobno, obveza prikazivanja efektivne kamatne stope eliminira ekonomsku održivost modela koji se reklamira kao „besplatan” za potrošača, čime se otvara prijelaz prema eksplicitno cjenovnim BNPL proizvodima s niskim, ali vidljivim kamatnim stopama, što vodi do strukturne konvergencije BNPL-a i kreditnih kartica.

5.3. MARKETINŠKE KOMUNIKACIJE KAO EKONOMSKI TROŠAK

Restrikcija marketinških komunikacija iz članaka 7. i 8. CCD2 ne predstavlja isključivo pravno ograničenje, već generira mjerljiv ekonomski trošak unutar BNPL poslovnoga modela. Zabrana isticanja „0% kamate” bez popratnoga reprezentativnog primjera povećava prag pažnje potreban za konverziju, što logika poslovnoga modela povezuje s porastom troška privlačenja kupca (engl. *customer acquisition cost*, CAC). Stavins (2024) te podaci CFPB-a (2025) pokazuju da je BNPL korištenje najizraženije upravo među financijski ranjivijim potrošačima sa slabijom poviješću kreditiranja, što znači da obveza prikaza efektivne kamatne stope u svakom oglasu disproporcionalno snižava konverziju u upravo onom segmentu koji čini jezgru BNPL korisničke baze. Treća dimenzija odnosi se na ograničenje ciljanoga oglašavanja prema ranjivim potrošačima, što segmente s najvišom marginalnom konverzijom, mlađe potrošače s ograničenim kreditnim iskustvom, efektivno povlači izvan dosega tradicionalnih BNPL marketinških strategija. Iz ekonomske perspektive, marketinški dio CCD2 ne djeluje kao komunikacijska, već kao troškovna intervencija: vrijednosna ponuda BNPL-a kao „besplatne fleksibilnosti” postaje ekonomski neodrživa, što prisiljava industriju na transformaciju komunikacijskoga registra u smjeru transparentnoga prikaza cijene kredita.

5.4. KONKURENTSKA REPOZICIJA

Kumulativni učinak prethodnih mehanizama mjerljivo preraspodjeljuje konkurentske pozicije među segmentima industrije. Frost i suradnici (2019) u svojoj analizi strukturne transformacije financijskoga posredovanja argumentiraju da inovativni nebankarski akteri rastu najbrže ondje gdje raspolažu kapitalnim i tehnološkim resursima koji nadilaze njihovu izvornu specijalizaciju, što opisuje pojavu *BigTech* pružatelja u potrošačkom kreditu. Tradicionalne banke, koje već raspolažu kreditno-regulatornom infrastrukturom, suočavaju se s razmjerno najnižim marginalnim troškom prilagodbe; *BigTech* pružatelji poput Applea i PayPala raspolažu kapitalnom dubinom i integriranim ekosustavom koji apsorbira *compliance* troškove bez fundamentalne promjene poslovnoga modela; samostalni BNPL fintech akteri, poput

Klarne i regionalnih pružatelja u srednjoeuropskom okruženju, nalaze se u najnepovoljnijem položaju zbog visoke ovisnosti o niskoprihodnoj masi transakcija. Predviđena posljedica je trostruka: jačanje pozicije banaka i tehnoloških konglomerata, konsolidacija ili strateška akvizicija srednjih fintech aktera te izlaz manjih pružatelja iz tržišta. Konkurentska struktura BNPL industrije time se kreće od fragmentirane prema oligopolnoj konfiguraciji.

Razmotrene implikacije čine zajednički ekonomski supstrat regulatornoga šoka. Sažeti pregled transmisijских mehanizama i njihovih implikacija na poslovne modele donosi Tablica 2.

Tablica 2. Transmisijски mehanizmi CCD2 i implikacije na poslovne modele BNPL industrije

Regulatorna obveza	Transmisijски mehanizam	Implikacija na poslovni model
Proširenje područja primjene (čl. 2.)	BNPL kvalificiran kao kreditni odnos; ukinuta strukturna osnova regulatorne arbitraže	Pravna kvalifikacija svih BNPL transakcija kao ugovora o potrošačkom kreditu
Procjena kreditne sposobnosti (čl. 18.)	Uspostava paralelne kreditne infrastrukture; produljenje korisničkoga puta	Porast fiksnih i varijabilnih troškova; narušavanje trenutačnosti checkout iskustva
Predugovorne informacije i SECCI (čl. 10.–13.)	Pretvaranje jednoslojnog checkouta u višeslojnu pravnu transakciju	Pad stope dovršenja transakcija; rast operativnoga troška obrade
Marketinške komunikacije (čl. 7. i 8.)	Restrikcija „0% kamate” oglašavanja; obveza reprezentativnoga primjera	Porast CAC-a; transformacija vrijednosne ponude od „besplatne fleksibilnosti” prema cjenovno transparentnomu kreditnom proizvodu

Izvor: Autorska razrada na temelju Direktive (EU) 2023/2225 te Cherednychenko (2024).

5.5. POZITIVNI UČINCI REGULACIJE NA ODRŽIVOST TRŽIŠTA

Uz dosad analizirane troškovne i strukturne pritiske, potrebno je istaknuti i potencijalne pozitivne učinke regulatornoga okvira na dugoročnu održivost BNPL tržišta. Standardizacija predugovornih informacija smanjuje informacijsku asimetriju između pružatelja i potrošača, čime se jača povjerenje potrošača kao temeljni preduvjet održive potražnje za digitalnim kreditnim uslugama. Obvezna procjena kreditne sposobnosti, iako kratkoročno povećava troškove, dugoročno smanjuje stope neplaćanja i kreditne gubitke, stabilizirajući prihodovnu osnovu industrije i smanjujući rizik prekomjerne zaduženosti potrošača koji je dosad predstavljao glavni reputacijski teret sektora. Konačno, regulatorna jasnoća smanjuje pravnu neizvjesnost poslovanja, olakšava pristup institucionalnom financiranju i legitimira BNPL kao trajnu komponentu potrošačko-kreditnoga sustava, a ne regulatornu anomaliju (Cherednychenko, 2024). U tom smislu, Direktiva se može tumačiti i kao mehanizam sazrijevanja industrije koji kratkoročni trošak prilagodbe zamjenjuje dugoročnom stabilnošću i vjerodostojnošću tržišta.

6. HRVATSKA PERSPEKTIVA

Stanje potrošačkoga kreditiranja u Hrvatskoj služi kao polazna točka za procjenu utjecaja CCD2 na domaće tržište. Prema podacima Hrvatske narodne banke (2025), ukupna vrijednost kredita kućanstvima na kraju studenoga 2025. iznosila je oko 27,3 milijarde eura, uz godišnji rast od 12,5 posto. Unutar te strukture, gotovinski nenamjenski krediti, funkcionalno najbliži

segmentu u kojemu BNPL djeluje, dosegli su približno 10,1 milijardu eura uz godišnji rast od 10,5 posto te odražavaju potrošačko zaduživanje koje je u prethodnome razdoblju dijelom operiralo izvan klasično definiranoga kreditno-regulatornoga okvira (Hrvatska narodna banka, 2025; Raiffeisenbank Austria, 2026).

6.1. STANJE BNPL TRŽIŠTA U HRVATSKOJ

Hrvatsko BNPL tržište, čije aktivne aktere sažima Tablica 3, karakterizira fragmentiranost između tri kategorije aktera: domaćih fintech rješenja, regionalnih pružatelja s fokusom na obročnu kupnju te tradicionalnih banaka koje već dugo nude plaćanje na rate kroz kreditne kartice. Strani fintech akteri, poput Klarne i PayPala, prisutni su prvenstveno kroz integraciju u *checkout* sustave online trgovaca, dok izravna lokalna potrošačka ponuda u Hrvatskoj zasad nije razvijena.

Tablica 3. Pregled aktivnih pružatelja BNPL usluga na hrvatskome tržištu

Pružatelj	Tip pružatelja	Tržišni model
Aircash	Domaći fintech	Mobilna aplikacija s odgodom plaćanja računa povezana s kartičnim poslovanjem
Leanpay	Slovenski fintech	Plaćanje na rate (6–36 mjeseci) bez kamata; financiranje u partnerstvu s Addiko Bankom d.d.
Klarna	Švedski fintech	Isključivo integracija u checkout online trgovaca; bez izravne lokalne potrošačke ponude
PayPal Pay in 4	BigTech (globalni)	Plaćanje u 4 rate kroz PayPal infrastrukturu; usluga trenutačno nije dostupna potrošačima u Hrvatskoj
Tradicionalne banke (PBZ, ZABA, RBA, OTP, Erste)	Bankarski BNPL	Plaćanje na rate povezano s kreditnim karticama

Izvor: Autorska sistematizacija na temelju podataka pružatelja (Aircash, 2025; Leanpay, 2025; Klarna, 2025) te Lider Media (2022) i Rep.hr (2024).

6.2. TRANSPOZICIJA CCD2 U HRVATSKO PRAVO

Direktiva (EU) 2023/2225 zahtijeva od država članica nacionalnu transpoziciju do 20. studenoga 2025., uz početak primjene 20. studenoga 2026. Cherednychenko (2024) ističe da uspjeh transpozicije ne ovisi isključivo o točnosti pravnoga prevođenja, već i o sposobnosti nacionalnoga zakonodavca da uskladi novu direktivu s postojećim institucionalnim okvirom potrošačke zaštite. U hrvatskome je kontekstu transpozicija provedena Zakonom o potrošačkim kreditima (NN 86/26), koji stupa na snagu 20. studenoga 2026. i zamjenjuje dotadašnji Zakon o potrošačkom kreditiranju (NN 75/09 i daljnje izmjene), harmoniziran s prethodnom Direktivom 2008/48/EZ. Novi propis u područje primjene uključuje i beskamratne kredite te kredite s rokom otplate do tri mjeseca, koji su prema prethodnome zakonu bili izuzeti, dok izvan područja primjene (čl. 4.) ostaje odgoda plaćanja koju trgovac odobrava sam uz podmirenje u roku do 50 dana, odnosno 14 dana za trgovce koji nisu mikro, mali ili srednji poduzetnici i ugovor sklapaju na daljinu. Odobrenja vjerovnicima i kreditnim posrednicima izdaje Hrvatska narodna banka (HNB), uz zadržanu nadležnost Hrvatske agencije za nadzor financijskih usluga

(HANFA) nad subjektima iz njezina djelokruga.⁵ Prijelaznim je režimom predviđena odgođena primjena pojedinih odredbi: članak 114. stavci 1. do 6., koji se odnose na pružatelje dotad izvan područja primjene prethodnoga zakona, stupaju na snagu 1. lipnja 2027., pri čemu su takvi vjerovnici i kreditni posrednici dužni zahtjev za odobrenje podnijeti najkasnije do 1. kolovoza 2027., dok se odredbe o obročnoj otplati po platnoj kartici i plaćanju na rate korisnika platne usluge (čl. 3. st. 2. t. 1. i 2.) primjenjuju tek od 1. siječnja 2028. Time je na razini nacionalnoga propisa potvrđena pravna kvalifikacija BNPL modela kao potrošačkoga kredita, dok konkretne posljedice za registraciju, supervizijski okvir i kapitalne zahtjeve ovise o poslovnom ustroju pojedinoga pružatelja.

6.3. SPECIFIČNOST HRVATSKOGA KONTEKSTA

Hrvatsko BNPL tržište nalazi se u ranoj razvojnoj fazi u odnosu na zapadnoeuropske zemlje, što znači da CCD2 regulatorno strukturira sektor prije njegova potpunoga razvoja. Iz te asimetrije proizlazi specifična dinamika: regulatorni okvir uspostavlja se istodobno s ulaskom najvećih međunarodnih igrača, pa će troškovi prilagodbe pogoditi i domaće i strane pružatelje u približno istome trenutku. Manja veličina hrvatskoga tržišta dodatno smanjuje sposobnost lokalnih fintech aktera za apsorpciju fiksnih regulatornih troškova, što stvara strukturnu prednost većih EU pružatelja s prekograničnim opsegom. Konačni ishod ovisit će o načinu na koji će se u praksi primjenjivati izuzeća preuzeta iz članka 2. stavka 8. Direktive te o dinamici primjene pojedinih odredbi nacionalnoga zakona.

Identificirani transmisijski mehanizmi mogu se povezati s konkretnim modelima pružatelja prisutnima na hrvatskome tržištu (Tablica 3). Obveza procjene kreditne sposobnosti najizravnije pogađa nebankarske modele obročne kupnje poput Leanpaya, čija konkurentnost počiva na brzini odobrenja na prodajnome mjestu, dok partnerstvo s licenciranom bankom otvara pitanje raspodjele regulatornoga troška unutar takvoga hibridnog modela. Za Aircash je ključno pitanje formalne klasifikacije kreditora iz točke 6.2., o kojemu ovise registracijske i supervizijske obveze. Tradicionalne banke, koje već posluju unutar okvira Zakona o potrošačkome kreditu, snose tek granični trošak prilagodbe, čime se teorijski projicirana strukturna prednost etabliranih aktera u hrvatskome kontekstu dodatno naglašava. Toj prednosti pridonosi i raspored primjene: dok se pružatelji koji dotad nisu bili obuhvaćeni propisom moraju licencirati tijekom 2027., obročna otplata po platnoj kartici ulazi u režim tek od 1. siječnja 2028., čime bankarski modeli dobivaju najdulje razdoblje prilagodbe. Ograničenje marketinških komunikacija ponajviše će se odraziti na checkout integracije stranih pružatelja, čija komunikacija počiva upravo na isticanju beskamtnosti i jednostavnosti odgode plaćanja.

Na toj se osnovi mogu skicirati tri teorijska scenarija razvoja tržišta nakon potpunoga uvođenja Direktive u hrvatski zakonodavni okvir. U prvome scenariju, uska transpozicija izuzeća iz članka 2. stavka 8. obuhvaća sve BNPL modele punim režimom regulacije, što ubrzava izlazak ili akviziciju manjih nebankarskih aktera i učvršćuje bankarsku dominaciju. U drugome scenariju, šira primjena izuzeća zadržava postojeću tržišnu strukturu, ali uz trajnu regulatornu neizvjesnost oko granica primjene. U trećemu scenariju, regulatorna jasnoća nakon transpozicije smanjuje ulazne barijere neizvjesnosti te potiče izravan ulazak velikih međunarodnih pružatelja s prekograničnim opsegom na hrvatsko tržište. Naglašavamo da su navedeni scenariji teorijske projekcije izvedene iz analitičkoga okvira rada, a ne empirijska

⁵Zakon o potrošačkim kreditima (NN 86/26) kvalifikaciju vezuje uz obilježja kreditnoga odnosa, a ne uz vrstu pružatelja. Supervizijski status pojedinoga BNPL pružatelja stoga ovisi o tome nastupa li kao vjerovnik, kreditni posrednik ili platna institucija, što ima različite posljedice za registraciju i kapitalne zahtjeve.

predviđanja, te da će njihov konačni ishod ovisiti o odlukama nacionalnoga zakonodavca i poslovnim strategijama pojedinačnih aktera.

7. ZAKLJUČAK

Provedena analiza pokazala je da Direktiva (EU) 2023/2225 ne djeluje kao izolirana pravna intervencija, već kao kumulativni regulatorni šok koji preustrojava poslovne modele BNPL industrije kroz četiri međusobno povezana transmisijska mehanizma – proširenje područja primjene, obvezu procjene kreditne sposobnosti, standardizaciju predugovornih informacija i ograničenje marketinških komunikacija. Svaki od navedenih mehanizama generira specifičan tip troška ili strukturnoga ograničenja koji se zajedno akumuliraju u rekonfiguraciju troškovne strukture, prihodovne logike i konkurentskih odnosa unutar industrije.

Doprinos rada leži u sistematiziranju tih mehanizama u koherentan analitički okvir koji povezuje regulatornu odredbu, ekonomski mehanizam i implikaciju na poslovni model. Iz toga okvira proizlaze četiri razine implikacija. Za industriju, regulatorni teret disproporcionalno opterećuje samostalne fintech aktere, otvarajući prostor konsolidaciji te jačanju tradicionalnih banaka i *BigTech* pružatelja. Za potrošače, viša razina zaštite ostvaruje se na trošak smanjenoga izbora i mogućega isključivanja dijela korisnika iz pristupa kreditu. Za regulatore, CCD2 funkcionira, kako tumači Cherednychenko (2024), kao model naknadne regulatorne intervencije nakon razdoblja tržišne ekspanzije izvan postojećega okvira, što otvara širu raspravu o ravnoteži između prostora za inovaciju i potrošačke zaštite u digitalnoj ekonomiji. Za hrvatsko tržište, koje se nalazi u ranoj razvojnoj fazi, CCD2 strukturira sektor prije njegova potpunog formiranja, čime stvara specifičnu dinamiku istodobnoga regulatornog šoka i tržišnoga ulaska međunarodnih aktera.

Rad ima i ograničenja koja treba imenovati. Analiza je interpretativne i teorijsko-analitičke prirode, bez primarnih empirijskih podataka, što je razumljivo s obzirom na to da se Direktiva u trenutku pisanja još ne primjenjuje. Stoga zaključke o tržišnoj konsolidaciji, rastu troškova i promjeni konkurentske strukture treba razumjeti kao teorijske projekcije utemeljene na argumentacijskoj analizi, koje tek predstoji empirijski provjeriti nakon početka primjene Direktive. Analiza je zaključena u lipnju 2026., prije donošenja hrvatskoga provedbenog propisa, pa pojedine specifičnosti nacionalne primjene i podzakonske razrade mogu dodatno modificirati izvedene implikacije. Konačno, analiza se oslanja na javno dostupne podatke o pružateljima i tržišnoj strukturi, bez uvida u interne poslovne pokazatelje pojedinačnih aktera, a treba napomenuti i da ne postoji jedinstvena službena europska statistika o broju BNPL korisnika, zbog čega procjene veličine tržišta variraju među komercijalnim izvorima ovisno o primijenjenoj definiciji.

Pravci budućih istraživanja proizlaze izravno iz tih ograničenja. Prvo, empirijsko praćenje stvarnoga *compliance* troška u prvih dvadeset i četiri mjeseca primjene Direktive dat će kvantitativnu potvrdu predviđenih učinaka. Drugo, komparativna analiza nacionalnih transpozicija u državama članicama EU otkrit će raspon regulatorne diskrecije i njezine ekonomske posljedice. Treće, analiza preživljavanja samostalnih BNPL fintech aktera u post-CCD2 razdoblju omogućit će izravan test hipoteze o konsolidaciji tržišta razvijene u ovome radu.

REFERENCE

1. Agarwal, S., Driscoll, J. C., Gabaix, X., i Laibson, D. (2009). The age of reason: Financial decisions over the life cycle and implications for regulation. *Brookings Papers on Economic Activity*, 2009(2), 51–117. <https://doi.org/10.1353/eca.0.0067>
2. Aircash. (2025). Naknade i opći uvjeti poslovanja. <https://aircash.eu/fees/>
3. Bar-Gill, O. (2012). *Seduction by contract: Law, economics, and psychology in consumer markets*. Oxford University Press. <https://doi.org/10.1093/acprof:oso/9780199663361.001.0001>
4. Berg, T., Burg, V., Gombović, A., i Puri, M. (2020). On the rise of FinTechs: Credit scoring using digital footprints. *The Review of Financial Studies*, 33(7), 2845–2897. <https://doi.org/10.1093/rfs/hhz099>
5. Cherednychenko, O. O. (2024). On the bumpy road to responsible lending in the digital marketplace: The new EU Consumer Credit Directive. *Journal of Consumer Policy*, 47(2), 241–270. <https://doi.org/10.1007/s10603-024-09564-z>
6. Consumer Financial Protection Bureau. (2025). The buy now, pay later market (Market report, calendar years 2019–2023). <https://www.consumerfinance.gov/data-research/research-reports/the-buy-now-pay-later-market/>
7. Cornelli, G., Frost, J., Gambacorta, L., Rau, P. R., Wardrop, R., i Ziegler, T. (2023). Fintech and big tech credit: Drivers of the growth of digital lending. *Journal of Banking and Finance*, 148, 106742. <https://doi.org/10.1016/j.jbankfin.2022.106742>
8. Creswell, J. W. (2014). *Research design: Qualitative, quantitative, and mixed methods approaches* (4. izd.). SAGE Publications.
9. Di Maggio, M., Williams, E., i Katz, J. (2022). Buy now, pay later credit: User characteristics and effects on spending patterns (NBER Working Paper No. 30508). National Bureau of Economic Research. <https://doi.org/10.3386/w30508>
10. Direktiva 2008/48/EZ Europskog parlamenta i Vijeća od 23. travnja 2008. o ugovorima o potrošačkim kreditima i stavljanju izvan snage Direktive Vijeća 87/102/EEZ. (2008). Službeni list Europske unije, L 133, 66–92. <https://eur-lex.europa.eu/eli/dir/2008/48/oj>
11. Direktiva (EU) 2023/2225 Europskog parlamenta i Vijeća od 18. listopada 2023. o ugovorima o potrošačkim kreditima i stavljanju izvan snage Direktive 2008/48/EZ. (2023). Službeni list Europske unije, L 2023/2225. <https://eur-lex.europa.eu/eli/dir/2023/2225/oj>
12. European Banking Authority. (2020). Guidelines on loan origination and monitoring (EBA/GL/2020/06). <https://www.eba.europa.eu/regulation-and-policy/credit-risk/guidelines-on-loan-origination-and-monitoring>
13. Frost, J., Gambacorta, L., Huang, Y., Shin, H. S., i Zbinden, P. (2019). BigTech and the changing structure of financial intermediation. *Economic Policy*, 34(100), 761–799. <https://doi.org/10.1093/epolic/eiaa003>
14. Horvat, J. (2024). Akademski bonton – (ne)pisana pravila akademske zajednice. Ekonomski fakultet u Osijeku.
15. Hrvatska narodna banka. (2025). Krediti kreditnih institucija prema institucionalnim sektorima i namjeni (stanje na dan 30. studenoga 2025.) [Statistički podaci]. <https://www.hnb.hr/statistika>
16. Juniper Research. (2025). Buy now, pay later: Market forecasts, competitor analysis and market segmentation 2025–2030. Juniper Research.
17. Klarna. (2025). Purchase countries, currencies and locales [Klarna Docs]. <https://docs.klarna.com>
18. Leanpay. (2025). Kratko predstavljanje Leanpay i ustup potraživanja partneru (Addiko Bank d.d.). <https://help.leanpay.com/hr/knowledge>

19. LendingTree. (2025). Buy now, pay later statistics [BNPL Tracker].
<https://www.lendingtree.com/personal/buy-now-pay-later-loan-statistics/>
20. Lider Media. (2022, 23. svibnja). Slovenci doveli koncept 'kupi sada, plati kasnije' na hrvatsko tržište. <https://lidermedia.hr/financije/slovenci-doveli-koncept-kupi-sada-plati-kasnije-na-hrvatsko-trziste-142953>
21. Philippon, T. (2016). The FinTech opportunity (NBER Working Paper No. 22476). National Bureau of Economic Research. <https://doi.org/10.3386/w22476>
22. Posner, R. A. (1974). Theories of economic regulation. *The Bell Journal of Economics and Management Science*, 5(2), 335–358. <https://doi.org/10.2307/3003113>
23. Raiffeisenbank Austria d.d. (2026, 23. siječnja). Hrvatska: U studenom 2025. nastavljeno snažan rast stambenih kredita. <https://www.rba.hr/hr/istrazivanja/2026/01-23-3.html>
24. Rep.hr. (2024). Švedski FinTech Klarna širi se na Hrvatsku.
<https://rep.hr/vijesti/financije/svedski-fintech-klarna-siri-se-na-hrvatsku/7497/>
25. Research and Markets. (2025, 24. veljače). Buy now pay later business and investment opportunities databook (Q1 2025 update). Research and Markets.
<https://www.researchandmarkets.com>
26. Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333–339.
<https://doi.org/10.1016/j.jbusres.2019.07.039>
27. Stavins, J. (2024). Buy now, pay later: Who uses it and why (Current Policy Perspectives No. 2024-3). Federal Reserve Bank of Boston, Research Department.
<https://www.bostonfed.org/publications/current-policy-perspectives/2024/buy-now-pay-later-who-uses-it-why.aspx>
28. Stigler, G. J. (1971). The theory of economic regulation. *The Bell Journal of Economics and Management Science*, 2(1), 3–21. <https://doi.org/10.2307/3003160>
29. Worldpay. (2025). Global payments report 2025 (10th ed.). Worldpay/FIS.
<https://www.worldpay.com/en-GB/global-payments-report-2025>
30. Zakon o potrošačkim kreditima, NN 86/26. Narodne novine. https://narodne-novine.nn.hr/clanci/sluzbeni/2026_08_86_1071.html
31. Zakon o potrošačkom kreditiranju, NN 75/09 (i daljnje izmjene). Narodne novine.
https://narodne-novine.nn.hr/clanci/sluzbeni/2009_06_75_1786.html

MARKET ENTRY AND BRAND POSITIONING STRATEGIES IN THE PLANT-BASED FOOD SECTOR: A COMPARATIVE ANALYSIS OF GLOBAL LEADERS AND EMERGING MARKET PLAYERS

MILOŠ MILOVANČEVIĆ

Faculty of Mechanical Engineering, University of Niš
A. Medvedeva 14, 18000 Niš, Serbia
milos.milovancevic@masfak.ni.ac.rs

PETRA KARANIKIĆ

Faculty of Biotechnology and Drug Development, University of Rijeka
Radmile Matejcic 2, 51000 Rijeka, Croatia
pkaranikic@biotech.uniri.hr

BARBARA PUH

Faculty of Economics and Business, University of Dubrovnik
Branitelja Dubrovnika 41, 2000 Dubrovnik, Croatia
barbara.puh@unidu.hr

ABSTRACT

The plant-based food sector has expanded rapidly, yet comparative evidence on market-entry and brand-positioning strategies remains limited in Central and Eastern Europe. This study examines how documented strategies differ between three international leaders (Beyond Meat, Impossible Foods, Oatly) and three Serbian producers (Imlek Oaza, BeGe Vege, Vegapčić Group). Using inductive qualitative document analysis grounded in the Gioia methodology, 19 documents published between 2016 and 2024 were coded into six dimensions: product innovation and differentiation, market expansion, health communication, strategic partnerships, sustainability positioning, and price accessibility. International-company materials emphasize science-based innovation, sequential specialist-to-mainstream expansion, high-visibility partnerships, quantified sustainability communication, and long-term price-parity goals; Serbian-company materials emphasize cultural adaptation, established or specialized distribution, functional health information, operational/local partnerships, less quantified sustainability communication, and current affordability. The international cases reflect strategies documented across their principal Western and international markets, whereas Serbian cases are examined in Serbia; this is therefore not a matched-market comparison. Because consumer preferences and comparable performance outcomes are not measured, the study does not rank strategy effectiveness. Its contribution is a six-dimension comparative framework for subsequent consumer- and performance-based research in the CEE context.

KEYWORDS: plant-based food, market entry strategies, brand positioning, Gioia methodology, emerging markets, comparative analysis, Serbia

1. INTRODUCTION

Plant-based meat and dairy alternatives have moved from niche offerings toward broader food-market visibility, supported by technological advances, health-oriented consumption, and sustainability concerns (Andreani et al., 2023; Yang, 2023). Market forecasts also indicate substantial long-term growth potential (Mintel, 2025). For firms, however, category growth does not remove the strategic problem of how to enter markets, differentiate products, communicate value, build distribution, and make new products acceptable to consumers with established food habits.

The best-documented strategic trajectories come from international brands such as Beyond Meat, Impossible Foods, and Oatly. Their cases illustrate combinations of product technology, specialist and mainstream channels, partnerships, health narratives, and sustainability claims. These cases are useful as observable strategy patterns, but their outcomes cannot be attributed to individual practices without common performance measures. This distinction is important when comparing them with smaller domestic firms operating under different organizational and market conditions.

Research on plant-based marketing remains concentrated on Western markets, while Central and Eastern Europe (CEE) is less studied. Serbia offers an underexplored domestic setting in which established food companies and younger specialist producers are developing plant-based offers. In this study, Serbia is the market context for the three domestic cases only. The international companies are reconstructed from documents describing strategies in the Western and international markets where those strategies were developed and reported. The design therefore compares two documentary case groups rather than six firms observed in one identical market.

The research question is: How do documented market-entry and brand-positioning strategies differ between global market leaders and Serbian producers, and how can those differences be organized into a comparative framework? Using qualitative document analysis and the Gioia methodology, the study identifies recurring dimensions and compares how they are articulated across the two groups. It contributes by extending descriptive coverage to Serbian firms and by organizing heterogeneous evidence into six dimensions. The analysis is comparative and interpretive, not causal: market maturity, consumer preferences, organizational resources, and market success are not independently measured.

2. LITERATURE REVIEW

2.1. MARKET ENTRY STRATEGIES IN THE FOOD SECTOR

Market entry concerns the mode and sequence through which a firm commits resources and reaches customers (Root, 1987; Anderson & Gatignon, 1986). In food markets, entry choices are especially sensitive to cultural expectations, habitual consumption, and sensory acceptance (Hartmann & Siegrist, 2017). The internationalization literature also emphasizes incremental learning and growing market commitment (Johanson & Vahlne, 1977), while ecosystem perspectives highlight partners, distributors, and institutional actors that facilitate entry and category development (Tsaplin, 2018; Bonetti et al., 2024). For plant-based products, route-to-market choices are therefore part of positioning because they influence where consumers encounter, interpret, and trial an unfamiliar category.

2.2. BRAND POSITIONING IN THE FOOD INDUSTRY

Brand positioning defines the value proposition a firm seeks to occupy relative to alternatives (Kotler & Keller, 2012). In plant-based foods, differentiation can draw on sensory performance, health, convenience, cultural familiarity, sustainability, or value-for-money considerations (Rini et al., 2022; Singh et al., 2024). The flexitarian segment is particularly relevant because broader adoption depends on consumers who reduce, rather than completely avoid, animal products (Aschemann-Witzel et al., 2020). Consequently, successful positioning cannot be inferred from a single message; firms may combine functional claims with identity, lifestyle, cultural, or technological narratives.

2.3. SUSTAINABILITY AND CONSUMER BEHAVIOR

Sustainability is a prominent potential value proposition, but environmental attitudes do not automatically translate into purchasing behavior. The attitude-behavior gap means that sustainability claims may compete with taste, price, convenience, and health at the point of choice (Peattie, 2010). Communication can become more behaviorally relevant when claims are concrete, credible, socially meaningful, and easy to act upon (White et al., 2019). This makes the degree of sustainability quantification analytically important, while not implying that more sustainability communication is always more effective in every market.

2.4. LITERATURE SYNTHESIS AND ANALYTICAL DIMENSIONS

The literature and inductive coding jointly motivate six analytical dimensions. Product innovation and differentiation captures the technological, sensory, cultural, or brand-based basis of distinctiveness (Andreani et al., 2023; Jung et al., 2024). Market expansion captures route-to-market configuration and channel sequencing, including movement between specialist, food-service, online, and mainstream retail channels (Johanson & Vahlne, 1977). Health communication distinguishes functional nutritional information from broader lifestyle or performance narratives (Aschemann-Witzel et al., 2020). Strategic partnerships captures the use of chefs, retailers, food-service actors, packaging/technology partners, and other organizations for access, credibility, trial, or operational support (Bonetti et al., 2024). Sustainability positioning captures whether environmental value is peripheral, rhetorical, quantified, or integrated into the brand narrative (Peattie, 2010; White et al., 2019). Price accessibility captures how firms frame affordability, current price advantage, or future price-parity goals. Market expansion remains a separate dimension because channel configuration is observable in both groups even when no specific sequence can be labeled superior.

3. METHODOLOGY

3.1. RESEARCH DESIGN

The study adopts an interpretivist qualitative design because market-entry and positioning strategies are communicated through organizational narratives, public claims, channel decisions, and partner relationships whose meaning depends on context. Qualitative document analysis permits systematic comparison of such evidence across firms and time. The coding logic follows the Gioia methodology, which progresses from first-order concepts close to the documentary evidence, through researcher-developed second-order themes, to broader aggregate dimensions (Magnani & Gioia, 2023).

3.2. DATA COLLECTION AND COMPARISON BOUNDARIES

The corpus contains 19 documents published between 2016 and 2024: 13 concerning the three international companies and six concerning the three Serbian producers. Sources include company communications, business and marketing media, industry analyses, academic publications, and partner case materials. The period captures the phase in which contemporary plant-based meat and dairy alternatives gained wider commercial visibility. The smaller Serbian corpus reflects lower public-document availability and the more recent entry of some domestic products; it is treated as a limitation rather than as evidence of weaker strategy.

Case contexts were defined before comparison. International-company evidence describes strategies used across the firms' principal Western and international markets. Serbian-company evidence concerns the domestic Serbian market. The study therefore does not test whether 'market maturity' differs between otherwise matched settings. Nor does it contain standardized data on sales, market share, profitability, brand equity, willingness to pay, matched retail prices, or Serbian consumer preferences. These boundaries prevent causal claims about why the observed strategic patterns differ and prevent ranking their effectiveness.

3.3. DATA ANALYSIS: GIOIA METHODOLOGY

Documents were read iteratively and coded for statements or observations related to product differentiation, channels, health claims, partnerships, sustainability, and price. Similar first-order concepts were grouped into second-order themes, which were then consolidated into six aggregate dimensions applicable to both case groups. Constant comparison was used to check that categories remained distinguishable and grounded in the corpus. Figure 1 summarizes the resulting data structure. The framework is used descriptively: the presence, absence, or form of a strategy in public documents is not interpreted as proof of consumer preference or market success.

Figure 1. Gioia data structure for market entry and brand positioning strategies in the plant-based food sector

1st-order concepts	2nd-order themes	Aggregate dimensions
Heme technology →	Science-based innovation →	Product innovation and differentiation
Protein texturization →	Functional differentiation →	
Traditional ćevapi / pljeskavice →	Cultural adaptation →	
Chef-first strategy →	Specialist/chef-first entry →	Market expansion strategies
Whole Foods meat-section placement →	Mainstream retail positioning →	
Serbian bioshops / online channels →	Specialized domestic distribution →	
Athlete endorsements →	Aspirational health narrative →	Health communication
Lactose-free / vitamin claims →	Functional health claims →	
Celebrity chefs / major chains →	Visibility / credibility partnerships →	Strategic partnerships

1st-order concepts	2nd-order themes	Aggregate dimensions
Tetra Pak cooperation →	Operational partnerships →	
CO2 labels / quantified impacts →	Quantified sustainability →	Sustainability positioning
General environmental claims →	Rhetorical / less quantified sustainability →	
Price-parity goals →	Scale-based affordability →	Price accessibility
Current local affordability →	Current-market accessibility →	

Source: Authors' Gioia-based coding structure derived from the documentary corpus

4. RESULTS

4.1. INTERNATIONAL COMPANIES: STRATEGIC DIMENSIONS

4.1.1. Product innovation and differentiation

International-company documents emphasize technology- and performance-based differentiation. Beyond Meat is described through protein-processing approaches intended to reproduce meat-like texture and appearance; Impossible Foods through heme-based product development and intensive food science; and Oatly through the functional performance of oat milk, especially texture and foaming in coffee applications. Across these cases, product functionality is closely linked to a science or performance narrative rather than to cultural localization.

4.1.2. Market expansion strategies

A recurring pattern is movement from credibility-building specialist or food-service settings toward broader distribution. Impossible Foods used chef and restaurant partnerships before large-chain expansion; Oatly built visibility through specialty coffee shops and baristas before mass retail; Beyond Meat sought placement alongside conventional meat to frame the product as a direct substitute. The common analytical feature is channel sequencing, not evidence that this sequence is universally optimal.

4.1.3. Health communication

Health communication varies by brand but often extends beyond basic functional claims. Beyond Meat has used athlete associations to connect plant-based consumption with performance; Impossible Foods emphasizes nutritional comparison and adequacy; Oatly has used provocative lifestyle-oriented messaging. These approaches illustrate performance, evidence-based, and identity-oriented health narratives, although the present study does not measure how consumers respond to them.

4.1.4. Strategic partnerships

Partnerships are used for several documented functions: culinary credibility, consumer trial, distribution access, and visibility. Examples include chef collaborations, major restaurant chains, mainstream retailers, and specialty coffee partners. Their importance in the framework

lies in the role assigned to the partner, not in an assumption that famous or large partners necessarily generate superior outcomes.

4.1.5. Sustainability positioning

Sustainability is visibly integrated into the international-company materials. Environmental benefits are often presented through quantified indicators concerning emissions, land, or water, and Oatly additionally uses activist-style climate communication. The evidence therefore supports a difference in the form and quantification of sustainability messaging, but not a conclusion that this form is better aligned with Serbian consumers.

4.1.6. Price accessibility

Beyond Meat and Impossible Foods publicly frame price parity with conventional meat as a long-term objective to be supported by scale and production efficiency. In the coded evidence, price accessibility is therefore primarily prospective: it is a stated pathway toward wider adoption rather than proof that current international products are cheaper or more accessible in Serbia.

4.2. SERBIAN COMPANIES: STRATEGIC DIMENSIONS

4.2.1. Product innovation and differentiation

Serbian-company materials emphasize cultural and brand familiarity. BeGe Vege and Vegapčić Group offer plant-based versions of familiar formats such as ćevapi, pljeskavice, and sausages, while Imlek Oaza combines plant-based beverages with an established dairy-company brand and vitamin-fortification claims. The differentiation logic is thus localized and familiarity-oriented rather than centered on proprietary biotechnology.

4.2.2. Market expansion strategies

The domestic cases show more than one route to market. Imlek can use an existing mainstream distribution network, whereas smaller producers rely more on specialist health-food shops, online channels, and selected restaurants. Specialized distribution is treated here as a distinct configuration associated with firm resources and access, not as an inferior version of international niche-to-mainstream sequencing.

4.2.3. Health communication

Serbian materials rely mainly on functional information such as lactose absence, lower saturated fat or cholesterol, vitamin fortification, and clean-label claims. This differs in tone from athlete, lifestyle, or performance narratives in some international cases. The documents show what firms emphasize; they do not establish that these messages correspond to the most important concerns of Serbian consumers.

4.2.4. Strategic partnerships

Domestic partnerships are documented mainly around operations and channel access. Imlek's cooperation with Tetra Pak supports packaging and production capabilities, while smaller firms work with specialized retailers and restaurants. These partnerships serve different functions from celebrity-chef or global-chain collaborations and should not be ranked as weaker without evidence on cost, reach, credibility, or commercial results.

4.2.5. Sustainability positioning

Environmental themes are present but generally less quantified in the Serbian-company corpus, with broader associations to plant-based or local production rather than detailed impact metrics. The data therefore support a communication-form difference. They do not support attributing that difference to Serbian consumer priorities or interpreting it as a preference mismatch.

4.2.6. Price accessibility

Serbian-company materials more often frame affordability as a current local-market consideration, including accessibility relative to imported or premium alternatives. This differs from the international firms' long-term parity objective. Because the corpus does not contain standardized matched-price data, the study cannot determine which group is objectively more affordable across comparable products and channels.

5. COMPARATIVE ANALYSIS AND DISCUSSION

The comparison identifies differences in strategic emphasis, but the evidence does not establish the causes of those differences. In product innovation, international firms foreground proprietary food science and sensory performance, whereas Serbian firms foreground familiar formats, local culinary meaning, and established brand trust. These are alternative differentiation mechanisms. Firm size, age, technical capabilities, product category, and resource availability are plausible explanations, but none is independently measured here.

Market expansion is analytically relevant because both groups make observable route-to-market choices. International cases commonly show specialist or high-visibility entry followed by wider food-service or retail distribution. Serbian cases range from immediate use of an established mainstream network (Imlek) to specialist retail, restaurants, and online channels. The comparison therefore concerns channel configuration and sequence. Specialized channels cannot be classified as inferior without evidence on target-market fit, conversion, cost, reach, or profitability.

Health communication also differs in form. International materials more often combine nutrition with lifestyle, performance, or identity narratives, while Serbian materials emphasize functional information and ingredient attributes. The study can describe this contrast, but it cannot infer that functional benefits are the 'immediate concerns' of Serbian consumers, because no consumer survey, experiment, or behavioral dataset was analyzed. The same caution applies to aspirational messaging: its lower visibility in the Serbian corpus is an observed communication pattern, not evidence of misalignment with local preferences.

Strategic partnerships deserve separate comparison because they perform different documented roles. International partnerships frequently combine visibility, trial, distribution, and external credibility; domestic partnerships are more often operational or channel-focused. A prestige partnership may offer reach but can also carry costs and fit risks, while a technology or specialist-retailer partnership may be highly valuable for quality or access. The data do not provide a common outcome measure with which to rank these partnership types.

Sustainability positioning shows the clearest communication-form contrast: quantified impact claims and activist narratives are more visible in the international corpus, while Serbian claims

are less frequently quantified. This supports a difference in message construction, not a claim that Serbian firms are 'lagging.' Consumer research shows that sustainability can matter while still competing with price, taste, convenience, and health (Peattie, 2010; White et al., 2019); however, Serbian preferences were not measured in this study.

Price accessibility completes the six-dimension comparison. International cases frame lower prices and parity with conventional products as a future scale objective, whereas Serbian cases more often discuss current affordability in the domestic competitive context. Since products, pack sizes, channels, and observation dates are not standardized, no direct price-performance ranking is possible. Price accessibility is retained because affordability framing is part of positioning in both groups, but it should be tested with matched market data.

Taken together, the dimensions describe strategic configurations rather than a hierarchy. Cultural localization, specialist distribution, operational partnerships, and functional health claims may be rational choices in the Serbian context; equally, quantified sustainability, high-visibility partnerships, or identity-oriented storytelling are options observed in international cases. The present evidence supports treating these practices as hypotheses or benchmark options for testing, not as prescriptions to copy. Future work should connect the framework to Serbian consumer preferences, matched price and distribution data, and common indicators of market and brand performance.

Table 1. Comparative analysis of strategic dimensions

Strategic dimension	International companies	Serbian companies
Product innovation	Science-based / proprietary technology and sensory-performance emphasis	Cultural adaptation, familiar formats, established-brand leverage
Market expansion	Sequential specialist / food-service entry followed by broader channels	Existing mainstream distribution (Imlek) or specialized / online channels
Health communication	Performance, lifestyle, and nutritional-comparison narratives	Functional health information and clean-label claims
Strategic partnerships	Chefs, food-service chains, retailers, and baristas for visibility, trial, and access	Packaging / technology cooperation plus specialist retailer and restaurant access
Sustainability	More frequent quantified impact claims and activist-style communication	Less frequently quantified environmental communication
Price accessibility	Long-term price-parity objective through scale and efficiency	Current-market affordability framing; no matched-price comparison

Source: Authors' comparative synthesis of the coded documentary evidence

6. CONCLUSION

This study compared the documented market-entry and brand-positioning strategies of three international plant-based leaders and three Serbian producers using the Gioia methodology. Six

dimensions organize the evidence: product innovation and differentiation, market expansion, health communication, strategic partnerships, sustainability positioning, and price accessibility. International-company materials more often emphasize science-based differentiation, specialist-to-mainstream sequencing, high-visibility partnerships, quantified sustainability, and long-term price parity. Serbian-company materials more often emphasize cultural familiarity, existing or specialist domestic channels, functional health information, operational/local partnerships, less quantified sustainability communication, and current affordability.

These differences should not be interpreted as a performance ranking. The international cases are reconstructed from strategies reported across Western and international markets, whereas the Serbian cases are situated in Serbia. The study contains no common measures of sales, market share, profitability, brand equity, consumer preference, willingness to pay, or matched prices. It therefore cannot demonstrate that international strategies are superior, that Serbian firms are 'lagging,' or that Serbian consumers prefer one communication style over another.

The practical value of the framework is diagnostic. Managers can use the six dimensions to identify which strategic options are present in their own positioning and which alternatives merit testing. International practices such as quantified sustainability claims, new partnership types, or identity-oriented communication are potential experiments rather than universal recommendations; localized formats, specialist channels, and affordability-oriented positioning can likewise be legitimate strategic choices. Future research should combine company interviews with Serbian consumer surveys or experiments, matched price and channel data, and comparable performance indicators so that documented strategy differences can be linked to outcomes.

REFERENCES

1. Anderson, E., & Gatignon, H. (1986). Modes of foreign entry: A transaction cost analysis and propositions. *Journal of International Business Studies*, 17(3), 1–26.
2. Andreani, G., Sogari, G., Marti, A., Frolidi, F., Dagevos, H., & Martini, D. (2023). Plant-based meat alternatives: Technological, nutritional, environmental, market, and social challenges and opportunities. *Nutrients*, 15(2), 452.
3. Aschemann-Witzel, J., Gantriis, R., Fraga, P., & Perez-Cueto, F. J. A. (2020). Plant-based food and protein trend from a business perspective: Markets, consumers, and the challenges and opportunities in the future. *Critical Reviews in Food Science and Nutrition*, 61(18), 3119–3128.
4. Bonetti, G. G., Van Hooven, C., & Onorati, M. G. (2024). Planting seeds of change in foodstyles: Growing brand strategies to foster plant-based meat alternatives in the food market. *Preprints*.
5. Hartmann, C., & Siegrist, M. (2017). Consumer perception and behaviour regarding sustainable protein consumption: A systematic review. *Trends in Food Science & Technology*, 61, 11–25.
6. Johanson, J., & Vahlne, J.-E. (1977). The internationalization process of the firm: A model of knowledge development and increasing foreign market commitments. *Journal of International Business Studies*, 8(1), 23–32.
7. Jung, M., Lee, Y., Han, S., & Hyeon, J. (2024). Advancements in sustainable plant-based alternatives: Exploring proteins, fats, and manufacturing challenges in alternative meat production. *Journal of Microbiology and Biotechnology*, 34, 994–1002.
8. Kotler, P., & Keller, K. L. (2012). *Marketing management (14th ed.)*. Pearson Education.

9. Magnani, G., & Gioia, D. (2023). Using the Gioia Methodology in international business and entrepreneurship research. *International Business Review*, 32(2), 102097.
10. Mintel. (2025). *Emerging trends in the plant-based industry*. Mintel Group.
11. Peattie, K. (2010). Green consumption: Behavior and norms. *Annual Review of Environment and Resources*, 35(1), 195–228.
12. Rini, L., Schouteten, J., Faber, I., Bechtold, K., Perez-Cueto, F., Gellynck, X., & De Steur, H. (2022). Identifying the key success factors of plant-based food brands in Europe. *Sustainability*, 15(1), 306.
13. Root, F. R. (1987). *Entry strategies for international markets*. Lexington Books.
14. Singh, S. B., Patil, R., & Jadhav, V. K. (2024). Plant based meat products: A sustainable, promising alternative to conventional red meat. *Biomedicine*, 44(1), 33–38.
15. Tsaplin, A. (2018). *Factors influencing the choice of market entry mode for emerging market firms*. Walden University.
16. White, K., Habib, R., & Hardisty, D. J. (2019). How to SHIFT consumer behaviors to be more sustainable: A literature review and guiding framework. *Journal of Marketing*, 83(3), 22–49.
17. Yang, C. (2023). *Research on plant-based food market implications and opportunities*. AEM Press.

TEXT OR VOICE? A CONCEPTUAL FRAMEWORK FOR MULTIMODAL AI SALES ASSISTANCE AND ITS EFFECTS ON PURCHASE DECISION-MAKING, TRUST, AND USER EXPERIENCE IN SPECIALIZED E-COMMERCE

TILEN MATJAŠIČ

Student, University of Maribor, Faculty of Organizational Sciences
Kranj, Slovenia
tilen.matjasic@student.um.si

ROBERT LESKOVAR

Full Professor, PhD
University of Maribor, Faculty of Organizational Sciences
Kranj, Slovenia
robert.leskovar@um.si

ABSTRACT

This paper develops a conceptual framework for how interaction modality shapes consumer responses to AI sales assistance in specialized e-commerce. Drawing on Media Richness Theory, e-commerce trust research and user-centric recommender-system work, it separates two effects that applied studies usually bundle together, namely adding conversational decision support to a storefront and delivering that support through speech instead of text. Eight propositions follow, each assessed against published experimental and survey evidence on chatbots, voice assistants and voice commerce. Exalyte Moto, a motorcycle-gear storefront developed by the first author, illustrates the framework with a catalog-grounded text advisor and a real-time voice interface. The case shows why one knowledge base, one language model, one prompt configuration and one catalog snapshot are preconditions for attributing an observed difference to modality instead of to content or model behavior. The framework decomposes conversational-commerce effects into an assistance contrast and a modality contrast, distinguishes retailer trust from trust in the AI advisor, and specifies the comparative design under which its propositions become testable.

KEYWORDS: artificial intelligence, conversational commerce, voice commerce, e-commerce, trust, user experience, purchase intention, social presence, multimodal interaction

1. INTRODUCTION

Conversational artificial intelligence is changing how online retail works. Instead of navigating category pages and filters, consumers can describe a need in natural language and receive a synthesized recommendation, and a voice interface lets them speak the request and hear the answer. Such interfaces may reduce search effort and make complex product information easier to process, but an AI interface also introduces uncertainty about competence,

reliability, privacy and the basis on which a recommendation was produced (Gefen et al., 2003; Hennighausen et al., 2025; Kim et al., 2008).

The distinction between text and voice matters theoretically. Media Richness Theory argues that communication media differ in their capacity to convey cues, provide feedback and resolve ambiguity (Daft & Lengel, 1986). Speech can increase social presence and anthropomorphic perceptions in retail settings, but a richer channel is not automatically a better one: voice can raise privacy concerns and reduce perceived user autonomy (Calahorra-Candao & Martín-de Hoyos, 2024; Huh et al., 2023; Sharma & Sharma, 2025). In an experimental comparison, voicebots raised cognitive and affective engagement relative to chatbots for experiential products (Rohit et al., 2024), and some consumers delegate part of the choice task to a voice assistant altogether (Mo et al., 2026).

Specialized motorcycle equipment suits this argument well. Consumers evaluate price, fit, comfort, materials, intended use and protective characteristics at the same time, and protective clothing reduces some soft-tissue injuries, though protection varies by garment and injury outcome (Wu et al., 2019). Recommendation quality and perceived expertise therefore carry more weight than in low-risk convenience purchases. Exalyte Moto is the illustrative case because it combines a conventional storefront, a catalog-grounded text advisor and a real-time voice interface (Exalyte Moto, 2026).

This paper is conceptual rather than empirical. It develops a framework that separates conversational assistance from the modality through which the assistance reaches the consumer. Three questions organize the argument. Q1: on what theoretical grounds should conversational AI assistance improve decision efficiency, trust, user experience and purchase intention relative to standard browsing, and how far does existing evidence support that expectation? Q2: once the decision engine and product information are held constant, what does speech add, and what does it cost, relative to text? Q3: for whom does conversational assistance matter most, given what is known about prior product knowledge and information search?

2. THEORETICAL FRAMEWORK AND PROPOSITIONS

The evidence base assessed in this paper was assembled through a structured but non-systematic search. Scopus, Web of Science and Google Scholar were searched between May and August 2026, combining interface terms (conversational agent, chatbot, voicebot, voice assistant, voice commerce, conversational commerce) with outcome terms (trust, social presence, purchase intention, user experience, decision-making, recommender system). Peer-reviewed studies reporting a consumer-facing retail or e-commerce context and an outcome corresponding to one of the focal constructs were retained; practitioner reports and studies without an identifiable consumer outcome were excluded. Foundational theory and measurement sources were added by backward citation tracking from the retained studies and are not date-restricted. The result is a purposive evidence base assembled to assess the propositions, not a census of the field.

2.1. AI ASSISTANCE, DECISION SUPPORT AND ONLINE TRUST

Online purchase decisions depend on what the shopper makes of the retailer and on how the interface behaves under use. Trust reduces perceived vulnerability, while useful and usable systems support behavioral intention (Gefen et al., 2003; Kim et al., 2008; McKnight et al.,

2002). A conversational advisor may improve the process by reducing a large product space to a smaller set of alternatives that fit the stated need, and the consumer outcome includes perceived system effectiveness, choice satisfaction and interaction experience as well as accuracy (Knijnenburg et al., 2012).

Catalog grounding of the kind implemented in Exalyte Moto (Section 3.1) is designed to reduce search effort and to make recommendations more relevant than unaided browsing, and it may transfer perceived competence from the advisor to the retailer. The first four propositions concern conversational assistance as such, meaning the common effect of text and voice assistance against an unassisted storefront.

P1: Conversational AI assistance reduces objective decision time relative to standard webshop browsing.

P2: Conversational AI assistance improves pragmatic user experience relative to standard webshop browsing.

P3: Conversational AI assistance raises retailer trust relative to standard webshop browsing.

P4: Conversational AI assistance raises purchase intention relative to standard webshop browsing, and decision-support quality carries part of that association.

Secondary evidence supports these propositions unevenly. P2 stands on the firmest ground, since perceived system effectiveness rather than accuracy alone drives the user response to recommendations (Knijnenburg et al., 2012). P4 combines that user-centric evidence with the established link between trust and online purchase intention (Gefen et al., 2003; Kim et al., 2008). P3 rests on a longer chain, because trusting beliefs are established antecedents of online purchase behavior (Gefen et al., 2003; McKnight et al., 2002) while the transfer of perceived competence from an AI advisor to the merchant deploying it is documented far less firmly, and labeling retailer communication as AI-assisted lowered trust in the retailer in an online experiment (Hennighausen et al., 2025). P1 is the weakest: reduced search effort is the standard argument, yet conversational turn-taking has costs of its own and none of the studies reviewed here measures decision time against a fixed catalog.

2.2. VOICE, MEDIA RICHNESS AND SOCIAL PRESENCE

Voice provides paralinguistic cues, synchronous turn-taking and a stronger sense of interpersonal exchange than typed text, which is what Media Richness Theory predicts should help with equivocal tasks (Daft & Lengel, 1986). Social presence has been linked to trust formation in e-commerce (Gefen & Straub, 2004).

The literature does not justify assuming a uniformly positive direct effect of voice on purchasing. In voice commerce, anthropomorphism itself heightens privacy concern and lowers behavioral intention (Sharma & Sharma, 2025), and shoppers differ in what they want an assistant to do for them (Mo et al., 2026). The framework therefore makes directional claims for the proximal mechanisms of social presence, perceived agent expertise and trust in the AI advisor, while treating the net association between voice and purchase intention as theoretically indeterminate.

One qualification governs the voice propositions below. The voice condition of the proposed design (Condition C, Section 4.1) does not present speech in isolation: the interface displays a running transcript, so the participant sees the exchange as well as hears it. The contrast is therefore between a text-only interface and a combined voice-and-text interface, and the incremental factor is the addition of the spoken channel rather than the replacement of text by speech. The design is deliberate, since a voice-only condition would remove the on-screen

product detail that the text condition supplies and would reintroduce the content difference the framework exists to exclude. P5 to P7 therefore concern what speech adds to a visible text exchange.

P5: Voice assistance produces higher perceived social presence than text assistance when the decision engine is held constant.

P6a: Voice assistance produces higher perceived agent expertise than text assistance.

P6b: Voice assistance produces higher trust in the AI advisor than text assistance.

P7: Voice assistance is associated with purchase intention indirectly, through social presence and trust in the AI advisor; its net association is theoretically indeterminate, because privacy concern and recognition error work against the social-presence pathway.

Read against published evidence, P5 has the firmest support: social presence rises with cue richness and immediacy, and it is an established antecedent of trust in B2C settings (Daft & Lengel, 1986; Gefen & Straub, 2004). P6a and P6b hold more conditionally. Human-like voice cues raise perceived safety (Calahorra-Candao & Martín-de Hoyos, 2024) and user autonomy shapes trust and purchase intention (Huh et al., 2023), but both studies vary cues within voice interfaces instead of comparing voice with text, so neither effect can be attributed to speech as such. On P7 the evidence divides. Anthropomorphism supports voice-commerce adoption through hedonic motives while lowering behavioral intention and raising privacy concern (Sharma & Sharma, 2025), and some consumers hand the choice task to the assistant instead of using it as an aid (Mo et al., 2026). Two opposing pathways of similar plausibility leave the net sign undetermined.

2.3. PRIOR PRODUCT KNOWLEDGE AS A BOUNDARY CONDITION

Consumers enter product-choice tasks with different levels of knowledge, and prior product knowledge changes the efficiency of information search (Brucks, 1985). A knowledgeable rider may already know which attributes matter and gain less from conversational guidance, while a novice may benefit more from having information reduced to a small set of recommendations. Prior knowledge is therefore a theoretically relevant moderator, not a background control variable.

P8: The benefit of conversational assistance for decision efficiency and perceived decision-support quality is larger for consumers with lower prior knowledge of motorcycle gear.

The evidence here is well established but indirect. Prior class knowledge facilitates the acquisition of new information and raises search efficiency (Brucks, 1985). That work predates conversational interfaces, so P8 extends a search-behavior finding to a new interface class. The opposite reading is also plausible, since experts may extract more from an advisor because they ask better-specified questions, in which case the moderation reverses.

3. ILLUSTRATIVE CASE: EXALYTE MOTO AND THE REQUIREMENT OF STIMULUS EQUIVALENCE

3.1. IMPLEMENTED SYSTEM COMPONENTS

Exalyte Moto was designed and developed by Tilen Matjašič. The system described here corresponds to the build of 27 August 2026, and the storefront has not been opened to customers, so first-time users meet it without prior exposure to the brand or its assistant. The text interface derives categories from the catalog, sends chat history and product records to a server-side product-chat function, and renders recommendations as cards with links, price, imagery and stock status. That function builds a catalog-grounded prompt and calls google/gemini-2.5-flash under rules restricting recommendations to the supplied catalog.

The voice interface is implemented separately with the ElevenLabs React conversation client. It requests microphone permission, obtains a conversation token from a Supabase edge function, starts a WebRTC session, displays user transcription and receives agent-response events.

Because the voice session is created through its own conversation-token function, it can in principle run a different system prompt and a different generation stack from the text advisor. Comparing two separate stacks leaves any observed difference open to product knowledge, model behavior, system instructions or response style, so a shared configuration is a precondition for any text-versus-voice claim.

3.2. STIMULUS EQUIVALENCE AS A DESIGN REQUIREMENT

Equivalence has a concrete specification in this case. Both AI conditions draw on the same fixed product snapshot, system instructions, response-length constraint, recommendation policy and text-generation endpoint. That shared engine has to be the product-chat function: typed text reaches it directly in Condition B, while in Condition C speech has to be transcribed, sent to the identical endpoint, and the returned text synthesized to speech. The visible transcript can stay in the voice condition, since it belongs to the intended multimodal experience, but product cards and factual information must come from the same catalog snapshot. Model version, temperature, prompt and catalog hash are frozen for the collection period.

4. AGENDA FOR EMPIRICAL VALIDATION

4.1. PROPOSED COMPARATIVE DESIGN

The propositions become testable through a randomized, between-subject, three-condition comparison with equal allocation: Condition A is standard browsing, Condition B text assistance and Condition C voice assistance over the same engine. Two orthogonal contrasts carry the framework. C1 compares standard browsing with the average of both assisted conditions and addresses P1 to P4; C2 compares text with voice and addresses P5 to P7. Because the contrasts are orthogonal, assistance and modality do not compete for the same variance, and P8 enters as an interaction between C1 and prior knowledge. Eligibility combines adult online-shopping experience with realistic interest in protective motorcycle equipment, and baseline subjective knowledge is measured before randomization so that it can stratify allocation.

Scale constrains such a study. A one-way three-group comparison at $\alpha = .05$, power = .80 and a medium effect of Cohen's $f = .25$ requires roughly 158 participants, and a target of 180, or 60 per condition, yields about 85% power. That benchmark is an assumption: if the true effects are smaller, as the divided evidence behind P7 suggests, a larger sample becomes necessary and the results have to be read through confidence intervals.

4.2. TASK AND PROCEDURAL REQUIREMENTS

Two procedural requirements follow from the framework. Device class has to be held constant, because microphone handling, screen space and navigation differ between desktop and mobile use. Prior product knowledge has to be recorded before the interface is assigned, since it moderates the effect in P8 and a post-exposure measurement is no longer a baseline.

The choice task carries the equivalence requirement into the participant experience. All conditions share one scenario and one fixed product set, and the task is to select the single product the participant would most seriously consider for a specified use case and budget. Several alternatives have to remain plausible, because a task solvable by picking a dominant option measures nothing about decision support. Decision time runs from the moment the interface becomes usable to the confirmation of a choice. A manipulation check on modality recognition belongs in the instrument but not in the exclusion rule, since excluding participants on a treatment-affected response biases causal estimates.

Piloting matters, because the equivalence claim is empirical. A pilot of twelve to eighteen participants tests task duration, microphone instructions, data logging and scale wording, and establishes whether text and voice responses stay substantively equivalent in content. Where they diverge, the modality contrast confounds speech with content, and a larger sample cannot remove that confound.

4.3. FOCAL CONSTRUCTS AND ESTABLISHED OPERATIONALIZATIONS

The framework draws on validated instruments, which is what makes its propositions comparable with the evidence reviewed above. Multi-item constructs use seven-point response formats, except for semantic differentials, which retain their original format. Where a validated scale is shortened or adapted to a specific storefront, the change has to be reported and the adapted version must not be described as the original instrument. Table 1 sets out the constructs with their sources.

Table 1. Focal constructs and established operationalizations

Construct	Operationalization	Applicability / source
Purchase intention	Three willingness/likelihood-to-buy items; 7-point scale.	Dodds et al. (1991).
Retailer trust	Competence, benevolence and integrity-oriented trusting-belief items.	McKnight et al. (2002).
Pragmatic UX	UEQ-S pragmatic quality items; hedonic quality retained as secondary descriptive score.	Schrepp et al. (2017).
Decision time	Seconds from usable interface to confirmed product choice; analyzed on log scale if right-skewed.	Objective telemetry.
Decision-support quality	Perceived relevance, usefulness and fit of information/recommendations to the task.	Informed by Knijnenburg et al. (2012).
Social presence	Perceived personalness, sociability and sense of human contact.	B vs C; Gefen and Straub (2004).
Agent expertise	Expertise/knowledge/qualification semantic-differential items.	AI conditions; Ohanian (1990).
Trust in AI advisor	Trust-in-automation items with minimal wording adaptation to the AI advisor.	AI conditions; Jian et al. (2000).
Subjective knowledge	Self-assessed motorcycle-gear familiarity/knowledge items measured before randomization.	Moderator; Brucks (1985).

5. PROPOSITIONS AND THE STATE OF SECONDARY EVIDENCE

Because the paper is conceptual, its propositions have to be judged on evidence that already exists. Table 2 records, for each one, the secondary evidence base and the comparison that would settle the question. Some propositions rest on directly relevant evidence, others extend findings from voice-only designs, and P1 and P7 are where evidence is thinnest or divided.

Table 2. Propositions, secondary evidence and the comparison that would settle each

Proposition	Secondary evidence base	Comparison that would settle it
P1	Search-effort argument only; decision time against a fixed catalog is not measured in the reviewed studies.	C1 on log decision time.
P2	Knijnenburg et al. (2012).	C1 on pragmatic UX.
P3	Gefen et al. (2003); McKnight et al. (2002); qualified by Hennighausen et al. (2025).	C1 on retailer trust.
P4	Gefen et al. (2003); Kim et al. (2008); Knijnenburg et al. (2012).	C1 on purchase intention, with decision-support quality as the indirect path.
P5	Daft and Lengel (1986); Gefen and Straub (2004).	C2 on social presence.
P6a	Huh et al. (2023); cues varied within voice interfaces, not against text.	C2 on perceived agent expertise, decision engine held constant.
P6b	Calahorra-Candao and Martín-de Hoyos (2024); Huh et al. (2023).	C2 on trust in the AI advisor, decision engine held constant.
P7	Divided: Mo et al. (2026); Sharma and Sharma (2025).	Serial indirect path from C2 through social presence and AI trust; net effect reported separately.
P8	Brucks (1985), predating conversational interfaces.	C1 by prior-knowledge interaction, with simple slopes.

6. IMPLICATIONS

6.1. THEORETICAL IMPLICATIONS

The framework's main theoretical value lies in decomposing conversational-commerce effects. Real systems change several things at once: recommendation logic, interface, response style, product knowledge and communication modality, so a comparison between a conventional webshop and a voice assistant cannot show whether an observed effect comes from AI assistance or from voice. The two contrasts separate the questions: C1 treats conversational decision support as a layer added to the same retailer and product set, while C2 addresses the incremental effect of speech once the decision engine is standardized. Published effects attributed to voice should therefore be read as effects of voice plus configuration until the configuration is shown to be constant.

The framework also distinguishes trust targets. Retailer trust is meaningful in all three conditions, whereas trust in the AI advisor exists only when an advisor is present, and collapsing

the two makes it impossible to tell whether an interface increases confidence in the merchant, in automation, or both. The distinction connects e-commerce trust research (Gefen et al., 2003; McKnight et al., 2002) with trust-in-automation measurement (Jian et al., 2000).

Finally, the framework treats voice as a modality with specified psychological mechanisms and an indeterminate net effect. Higher social presence plausibly raises trust and perceived expertise, while privacy concern, recognition error and reduced autonomy work in the opposite direction (Calahorra-Candao & Martín-de Hoyos, 2024; Huh et al., 2023; Sharma & Sharma, 2025). A null net voice effect is therefore compatible both with two substantial mechanisms of opposite sign and with the absence of either mechanism, and only a design that measures the mediators can tell these cases apart.

6.2. MANAGERIAL IMPLICATIONS FOR SPECIALIZED E-COMMERCE

For Exalyte Moto and comparable specialized retailers, the framework addresses a practical sequencing question: what to build first. Perceived system effectiveness rather than accuracy alone drives the user response to recommendations (Knijnenburg et al., 2012), and the engagement advantage of voicebots over chatbots depends on product type (Rohit et al., 2024), which points investment toward product-grounded text assistance, recommendation quality and catalog data before voice infrastructure. Voice earns its place where it raises social presence and advisor trust without adding decision time or privacy discomfort. If the gains concentrate among consumers with less product knowledge (Brucks, 1985), the assistant works as an onboarding tool and should be measured that way.

A second implication concerns evaluation. A retailer running an internal A/B test between a text advisor and a voice advisor faces the equivalence problem described in Section 3: a different prompt, model, catalog or response-length rule all change what the customer sees. In production these are acceptable engineering choices; in an evaluation they are confounds, and funding voice on the basis of such a test funds the whole bundle of changes rather than voice itself. Freezing catalog and model configuration for the duration of a test costs little and makes the resulting number interpretable.

6.3. ETHICS, PRIVACY AND TRANSPARENCY

Tilen Matjašič is both the developer of the storefront and an author of this paper, and Robert Leskovar supervises the research design. The dual role gives full control over the stimulus, which makes the equivalence requirement achievable, and it is also a source of bias that the fixed contrasts, validated measures and predefined comparisons are meant to constrain.

Several requirements precede any data collection. Ethics review at the Faculty of Organizational Sciences, University of Maribor, comes before recruitment, and participants are told before interaction that the advisor is AI-generated. The voice condition requires explicit browser microphone permission, and raw audio collection is minimized: where possible only the transcript and the telemetry needed for analysis are retained, with consent covering transcript retention. Tilen Matjašič acts as data controller on the basis of participant consent, and three processors take part in a session: ElevenLabs for speech-to-text and text-to-speech, Google for the model behind advisor responses, and Supabase for database and session handling. Because these services may process data outside the European Union, the information sheet states that such transfer can occur and that the research team retains no raw audio. Records are pseudonymized and held separately from recruitment identifiers, which are deleted once

collection closes; pseudonymized records are kept for five years, and participants may withdraw at any time without giving a reason.

These measures follow the transparency-oriented approach of Regulation (EU) 2024/1689 (European Parliament and Council, 2024). Disclosure that the advisor is AI-generated is treated as a design principle and as part of the treatment, and evidence on AI-mediated communication indicates that disclosure shapes trust formation (Hennighausen et al., 2025).

6.4. LIMITATIONS

The first limitation is that the eight propositions remain untested; they are derived from theory and assessed against published evidence, but none of that substitutes for a direct test. Other limitations would persist even in a standardized study. A hypothetical purchase task measures intention, not spending. A single brand and category limit external validity. Voice quality depends on microphone, accent, network conditions and recognition accuracy, which belong to user experience and also inflate variance. A fixed catalog buys internal validity at the cost of representing a live store. Recruitment through panels or rider communities is non-probability sampling, and a storefront without an established customer base speaks to first-encounter behavior, not habitual use.

Three extensions follow. A field study would add behavioral outcomes such as add-to-cart events, completed transactions and repeat use, which addresses the intention-behavior gap. A factorial extension would manipulate modality, explanation depth and product grounding independently. Cross-language replication would also be informative, because recognition accuracy and social cues differ across languages, and P5 is a claim about cues that language may modify.

7. CONCLUSIONS

This paper develops a conceptual framework for AI sales assistance in specialized e-commerce and separates two effects that applied work bundles together: conversational decision support, and the modality delivering it. Confronting each of the eight propositions with published evidence yields a graded picture rather than a uniform one.

The central claim states a condition for valid comparison, namely that text and voice cannot be compared across two different system prompts or two different generation stacks. Such a configuration confounds modality with content and model behavior, and part of the existing evidence on voice interfaces carries that ambiguity. Exalyte Moto shows what the alternative requires: one fixed knowledge base and one decision engine, with speech-to-text and text-to-speech as the only intended difference. P1 on decision time and P7 on the net effect of voice are where published evidence is thinnest or divided, and where an empirical study designed on these terms would contribute most.

AUTHOR CONTRIBUTIONS

Tilen Matjašič: conceptualization, application development, framework development, writing of the original draft. Robert Leskovar: supervision, conceptualization, methodology, writing review and editing.

DECLARATIONS

Funding: this research received no external funding. Conflict of interest: Tilen Matjašič developed the Exalyte Moto application that serves as the illustrative case in this paper; no other competing interests are declared. Data and materials: the application source code is proprietary and is not released, and no dataset accompanies this paper, since it reports no participant data. Preregistration: this conceptual paper is not preregistered and reports no data collection; the propositions, constructs and comparisons stated here are fixed in this version of the manuscript, dated 27 August 2026, and are intended as the pre-specified basis for the empirical study outlined in Sections 4 and 5.

REFERENCES

1. Brucks, M. (1985). The effects of product class knowledge on information search behavior. *Journal of Consumer Research*, 12(1), 1–16. <https://doi.org/10.1086/209031>
2. Calahorra-Candao, G., & Martín-de Hoyos, M. J. (2024). The effect of anthropomorphism of virtual voice assistants on perceived safety as an antecedent to voice shopping. *Computers in Human Behavior*, 153, Article 108124. <https://doi.org/10.1016/j.chb.2023.108124>
3. Daft, R. L., & Lengel, R. H. (1986). Organizational information requirements, media richness and structural design. *Management Science*, 32(5), 554–571. <https://doi.org/10.1287/mnsc.32.5.554>
4. Dodds, W. B., Monroe, K. B., & Grewal, D. (1991). Effects of price, brand, and store information on buyers' product evaluations. *Journal of Marketing Research*, 28(3), 307–319. <https://doi.org/10.1177/002224379102800305>
5. European Parliament and Council. (2024). Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). *Official Journal of the European Union*, L, 2024/1689. <https://eur-lex.europa.eu/eli/reg/2024/1689/oj>
6. Exalyte Moto. (2026). *Exalyte Moto storefront* [Web application]. Retrieved August 27, 2026, from <https://www.exalytemoto.com/>
7. Gefen, D., Karahanna, E., & Straub, D. W. (2003). Trust and TAM in online shopping: An integrated model. *MIS Quarterly*, 27(1), 51–90. <https://doi.org/10.2307/30036519>
8. Gefen, D., & Straub, D. W. (2004). Consumer trust in B2C e-commerce and the importance of social presence: Experiments in e-products and e-services. *Omega*, 32(6), 407–424. <https://doi.org/10.1016/j.omega.2004.01.006>
9. Hennighausen, C., Yarza Navarro-Schär, V. G., & Eller, E. (2025). AI-mediated communication in e-commerce: Implications for customer trust. *International Journal of Consumer Studies*, 49(5), Article e70111. <https://doi.org/10.1111/ijcs.70111>
10. Huh, J., Whang, C., & Kim, H.-Y. (2023). Building trust with voice assistants for apparel shopping: The effects of social role and user autonomy. *Journal of Global Fashion Marketing*, 14(1), 5–19. <https://doi.org/10.1080/20932685.2022.2085603>
11. Jian, J.-Y., Bisantz, A. M., & Drury, C. G. (2000). Foundations for an empirically determined scale of trust in automated systems. *International Journal of Cognitive Ergonomics*, 4(1), 53–71. https://doi.org/10.1207/S15327566IJCE0401_04
12. 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 Systems*, 44(2), 544–564. <https://doi.org/10.1016/j.dss.2007.07.001>

13. Knijnenburg, B. P., Willemsen, M. C., Gantner, Z., Soncu, H., & Newell, C. (2012). Explaining the user experience of recommender systems. *User Modeling and User-Adapted Interaction*, 22(4–5), 441–504. <https://doi.org/10.1007/s11257-011-9118-4>
14. McKnight, D. H., Choudhury, V., & Kacmar, C. (2002). Developing and validating trust measures for e-commerce: An integrative typology. *Information Systems Research*, 13(3), 334–359. <https://doi.org/10.1287/isre.13.3.334.81>
15. Mo, L., Sands, S., & Leckie, C. (2026). Outsourcing choice: AI voice assistants as shopping surrogates. *Journal of Retailing and Consumer Services*, 89, Article 104657. <https://doi.org/10.1016/j.jretconser.2025.104657>
16. Ohanian, R. (1990). Construction and validation of a scale to measure celebrity endorsers' perceived expertise, trustworthiness, and attractiveness. *Journal of Advertising*, 19(3), 39–52. <https://doi.org/10.1080/00913367.1990.10673191>
17. Rohit, K., Shankar, A., Katiyar, G., Mehrotra, A., & Alzeiby, E. A. (2024). Consumer engagement in chatbots and voicebots: A multiple-experiment approach in online retailing context. *Journal of Retailing and Consumer Services*, 78, Article 103728. <https://doi.org/10.1016/j.jretconser.2024.103728>
18. Schrepp, M., Hinderks, A., & Thomaschewski, J. (2017). Design and evaluation of a short version of the User Experience Questionnaire (UEQ-S). *International Journal of Interactive Multimedia and Artificial Intelligence*, 4(6), 103–108. <https://doi.org/10.9781/ijimai.2017.09.001>
19. Sharma, H., & Sharma, D. (2025). Does humanizing help? Exploring the role of anthropomorphism and privacy concerns in shoppers adoption of voice-commerce. *Marketing Intelligence & Planning*, 43(6), 1220–1250. <https://doi.org/10.1108/MIP-06-2023-0268>
20. Wu, D., Hours, M., Ndiaye, A., Coquillat, A., & Martin, J.-L. (2019). Effectiveness of protective clothing for motorized 2-wheeler riders. *Traffic Injury Prevention*, 20(2), 196–203. <https://doi.org/10.1080/15389588.2018.1545090>

PODUZETNIČKI MARKETING U DIGITALNOM DOBU: TEORIJSKI PREGLED I ILUSTRATIVNI PRIMJERI IZ POLJSKE I HRVATSKE

ANTE RONČEVIĆ

Sveučilište Sjever
Odjel za ekonomiju
Trg dr. Žarka Dolinara 1, 48000 Koprivnica
aroncevic@unin.hr

DANIJELA MAGDALENIĆ

Sveučilište Sjever
Doktorski studij Mediji i komunikacija
Trg dr. Žarka Dolinara 1, 48000 Koprivnica
danmagdalenic@unin.hr

SAŽETAK

Rad razmatra poduzetnički marketing u digitalnom okruženju i mogućnosti njegova povezivanja s Marketingom 6.0. Cilj je razgraničiti teorijske konstrukte i razviti okvir za interpretaciju dokumentiranih praksi. Primijenjen je ciljani narativni pregled literature uz analizu trinaest javno dostupnih dokumenata o CD Projektu, Booksyju, Rimcu i Infobipu. Prakse su razvrstane prema sedam dimenzija poduzetničkog marketinga, dok je strateška fleksibilnost razmotrena zasebno. Razlikuju se navodi izvora, interpretacije i nedovoljno dokumentirana obilježja. Primjeri ilustriraju tržišne prilike, prilagodbu ponude i mobilizaciju partnerskih resursa. Booksy i Infobip Shift pružaju ograničene poveznice fizičkog i digitalnog iskustva, ali korpus ne potvrđuje imerzivni marketing; ovo razdvajanje digitalne funkcionalnosti od imerzivnog iskustva glavni je nalaz rada. Doprinos rada jest analitički okvir koji povezuje praksu, dokaz i domet zaključka. Analizirana poduzeća u prikazanom razdoblju već su međunarodno etablirana, pa se nalazi odnose na primjenu poduzetničko-marketingških dimenzija u kasnijim razvojnim fazama, a ne na poduzetnički marketing malih i srednjih poduzeća u strogom smislu. Izvedene su tri propozicije za buduću provjeru. Nalazi ne dokazuju uzročne učinke poslovnog modela, razvojnih faza ili regionalnog podrijetla.

KLJUČNE RIJEČI: poduzetnički marketing, Marketing 6.0, digitalizacija, imerzivno iskustvo, analiza dokumenata, Poljska, Hrvatska

1. UVOD

Digitalizacija mijenja prepoznavanje prilika i isporuku vrijednosti, ali sama uporaba tehnologije ne objašnjava poduzetničku marketingšku praksu. Morris et al. (2002) povezuju poduzetničku i marketingšku perspektivu kroz sedam dimenzija, a Jones i Rowley (2011) razmatraju poduzetničku marketingšku orijentaciju. Različite konceptualizacije zahtijevaju dosljedan izbor analitičkog okvira.

Drugi je izazov razlikovanje digitalnih funkcija od Marketinga 6.0. Platforma, tehnološki proizvod ili korisnička zajednica nisu sami po sebi dokaz imerzivnog marketinga. Rad pokazuje da analizirana digitalna funkcionalnost dosljedno ne doseže prag imerzivnog iskustva; ovo razdvajanje digitalne funkcionalnosti od imerzivnosti glavni je nalaz i doprinos rada, dok su preostali rezultati ilustrativni.

Cilj rada jest povezati teorijski pregled s provjerljivim tumačenjem praksi četiriju poduzeća iz Poljske i Hrvatske. Doprinos je okvir koji za svaku praksu razdvaja dokaz poduzetničkog marketinga, poveznicu s oblikovanjem iskustva i granicu zaključivanja o Marketingu 6.0. Regionalno podrijetlo određuje izbor ilustracija, bez pretpostavke reprezentativnosti regije.

Treći je izazov konceptualan: poduzetnički marketing u izvornoj literaturi (Morris et al., 2002; Sadiku-Dushi et al., 2019; Sahu i Panda, 2024) opisuje ponašanje malih i srednjih poduzeća u uvjetima resursne oskudice i neizvjesnosti. Analizirana četiri poduzeća u dokumentiranom razdoblju već su međunarodno vidljivi, dobro financirani akteri. Rad zato ne tvrdi da su ta poduzeća u analiziranom trenutku bila mala ili resursno ograničena; predmet analize jest primjena poduzetničko-marketinških dimenzija na dokumentirane prakse rasta i partnerstva, neovisno o veličini poduzeća u trenutku prakse. Ta razlika izlaže se ovdje kao ograničenje tumačenja, ne kao nedostatak korpusa.

2. TEORIJSKI OKVIR

2.1. PODUZETNIČKI MARKETING I EMPIRIJSKI NALAZI

Poduzetnički marketing ovdje označava povezivanje tržišnih prilika, odnosa s kupcima i stvaranja vrijednosti s inovativnim djelovanjem i upravljanjem resursima u neizvjesnosti. Deduktivna osnova jest sedam dimenzija Morrisa et al. (2002). Tablica 1 daje radne indikatore za dokumentarnu analizu, a ne validiranu mjernu ljestvicu. Strateška fleksibilnost zasebno označava prilagodbu ponude, resursa ili tržišnog pristupa promijenjenim uvjetima; nije osma izvorna dimenzija.

Tablica 1. Dimenzije poduzetničkog marketinga i pravila interpretacije

Kod i dimenzija	Radno značenje	Dokumentarni indikator / granica
D1 Proaktivnost	Pokretanje djelovanja prema budućim potrebama.	Nova inicijativa s obrazloženom namjerom; sam rast nije dovoljan.
D2 Usmjerenost na prilike	Prepoznavanje i razrada tržišne mogućnosti.	Identificiran problem ili segment i konkretan odgovor.
D3 Inovativnost	Razvoj novog rješenja ili načina ponude.	Opis promjene proizvoda, usluge ili distribucije; bez tvrdnje o svjetskoj novosti.
D4 Promišljeno preuzimanje rizika	Procjena i upravljanje neizvjesnim ulaganjem.	Dokumentirana prethodna procjena ili ograničenje izloženosti; ulaganje samo nije dokaz.

D5 Intenzivna usmjerenost na kupce	Odnos i prilagodba potrebama korisnika.	Konkretna prilagodba ili povratna informacija; opća izjava o važnosti kupca nije dovoljna.
D6 Kreativno iskorištavanje resursa	Mobilizacija i kombiniranje dostupnih i partnerskih resursa.	Opis dopune resursa; ne izjednačuje se s nultim troškom.
D7 Stvaranje vrijednosti	Oblikovanje koristi za korisnika.	Jasna korisnička funkcija ili korist; razlikovati ponudu i izmjereni učinak.

Izvor: Dimenzije prema Morris et al. (2002); indikatori i pravila razvrstavanja razvijeni za ovaj pregled.

Jones i Rowley (2011) povezuju poduzetničku, tržišnu, inovacijsku i kupčevu orijentaciju. Različite ljestvice stoga ne treba spajati bez provjere sadržajne podudarnosti. Poduzetnički marketing također nije ograničen administrativnom definicijom malog poduzeća: predmet ovog rada jesu prakse.

Sadiku-Dushi et al. (2019), na uzorku 217 malih i srednjih poduzeća na Kosovu, nalaze nejednaku izraženost dimenzija, uz naglasak na prilikama i resursima. Zahara et al. (2023) analiziraju 197 poduzeća u Paluu u Indoneziji i izvješćuju o pozitivnim vezama poduzetničkog marketinga, digitalnih marketinških sposobnosti i marketinških rezultata. Ti nalazi podupiru razlikovanje praksi, sposobnosti i ishoda, ali ne potvrđuju Marketing 6.0.

Sahu i Panda (2024) anketiraju 302 vlasnika ili menadžera proizvodnih malih i srednjih poduzeća u Indiji. Nalaze djelomičnu posredničku ulogu inovacijskih rezultata u vezi poduzetničkog marketinga i uspješnosti. Yadav et al. (2024) razvijaju i ispituju ljestvicu od 62 čestice okvira EMICO za indijska novoosnovana poduzeća. Novija istraživanja tako nude mjerne pristupe i objašnjenja odnosa, uz potrebu provjere njihove prenosivosti među sektorima i državama.

2.2. MARKETING 6.0: ISKUSTVO I RAZGRANIČENJE

Oznaka Marketing 1.0 pripada tipologiji Kotlera et al. (2010), a ne Levittu. Humanistička usmjerenost pojavljuje se već u Marketingu 3.0 i nije razlikovna značajka Marketinga 6.0. Potonji naglašava približavanje fizičkog i digitalnog iskustva, tehnološke preduvjete, proširenu stvarnost i metaverzum te višesenzorna i prostorna iskustva. Metamarketing povezuje takva iskustvena okruženja izvan samog upravljanja komunikacijskim kanalima (Kotler et al., 2023, pogl. 1, 4–10).

Analiza odvojeno provjerava povezanost fizičkih i digitalnih dodirnih točaka, imerzivnu marketinšku interakciju te suoblikovanje iskustva. To je autorski filter, ne validirana ljestvica ili iscrpna definicija Marketinga 6.0. Imerzivnost zahtijeva opis interakcije koja korisnika uključuje u prostorno ili višesenzorno okruženje i njezine marketinške funkcije. Podaci korisnika potrebni su za zaključak o doživljenoj prisutnosti. Suoblikovanje zahtijeva mogućnost utjecaja na sadržaj ili tijek iskustva; registracija ili kupnja nisu dovoljne.

2.3. KONCEPTUALNE POVEZNICE I GRANICE

Whalen i Akaka (2016) povezuju poduzetnički marketing sa zajedničkim oblikovanjem prilika kroz djelovanje više sudionika. Time pružaju teorijsku poveznicu između prepoznavanja

potreba i oblikovanja iskustva, bez izjednačavanja stvaranja vrijednosti s određenom tehnologijom.

Predloženi odnos obuhvaća tri koraka: poduzetnička praksa prepoznaje problem korisnika; organizacijske i digitalne sposobnosti omogućuju odgovor; dokumentirana interakcija pokazuje kakvo se iskustvo nudi. Nalazi Zahare et al. (2023) te Saha i Pande (2024) podupiru važnost sposobnosti i inovacije, ali ne dokazuju treći korak. Marketing 6.0 usmjerava provjeru tog iskustvenog sadržaja (Kotler et al., 2023).

Povezanost je zato uvjetovana. Povjerenje i autentičnost mogu biti relevantni, ali ne razlikuju imerzivnu praksu od drugih pristupa. Trošak, pristupačnost i korisnička potreba mogu opravdati jednostavnije rješenje. Okvir omogućuje prepoznati i djelomičnu poveznicu, primjerice fizičko-digitalni kontinuitet bez dokazane imerzivnosti. Time se izbjegava kružno zaključivanje u kojem se svaka uspješna digitalna praksa unaprijed proglašava Marketingom 6.0.

3. PRISTUP PREGLEDU I ANALIZI

3.1. PRETRAŽIVANJE I ODABIR

Primijenjen je ciljani narativni pregled s ilustrativnom analizom dokumenata (Bowen, 2009; Snyder, 2019). Revizijsko pretraživanje provedeno je 8. rujna 2026. javnom mrežnom tražilicom i ciljanim pregledom izdavačkih, institucionalnih, poslovnih i medijskih stranica. Upiti su povezivali „entrepreneurial marketing”, „dimensions”, „SME performance”, „digital marketing capabilities”, „Marketing 6.0” i „immersive”. Nazivi poduzeća kombinirani su s „history”, „funding”, „investment”, „Cyberpunk refund”, „Shift acquisition”, „hybrid conference” i „salon software 2020”. Provjeravani su točni naslovi i DOI-jevi.

Uključeni su izvori relevantni za konstrukte i mjerenje te dokumenti koji podupiru konkretnu praksu. Za noviju empiriju prioritet su imali radovi od 2019. do datuma pretraživanja; zadržana su starija teorijska i metodološka uporišta. Isključeni su nedostupni oslonci poslovnih tvrdnji, nepovezani sadržaji i opće odredišne stranice. Kada je dostupan samo sažetak znanstvenog rada, preuzimanje je ograničeno na ondje navedenu metodu i nalaze.

Literatura obuhvaća 26 izvora: 11 znanstvenih i teorijsko-metodoloških izvora, dva institucionalna izvještaja i 13 dokumenata o poduzećima. Posljednji čine analitički korpus: devet objava poduzeća ili partnera i četiri medijska izvještaja (Tablica 2). Razmatraju se prakse do kraja 2021.; kasnije dostupne povijesne stranice koriste se retrospektivno. Marketing 6.0 služi naknadnoj interpretaciji, bez tvrdnje da su poduzeća tada usvojila taj naziv. Pregled nije sustavan ni iscrpan; nisu pretraživane zatvorene bibliografske baze.

3.2. PRIMJERI I REGIONALNI KONTEKST

Poduzeća su namjerno odabrana zbog poljskog ili hrvatskog podrijetla, međunarodne orijentacije, dostupnih dokumenata i različitih tržišnih odnosa: digitalnog sadržaja, posredovanja pri uslugama, industrijske suradnje i komunikacijske infrastrukture. Dvije zemlje pružaju kontrast veličine tržišta unutar regionalnog okvira, ali nisu izabrane radi procjene nacionalnog učinka. Podrijetlo nije izjednačeno s aktualnim sjedištem ili vlasništvom.

European Innovation Scoreboard za 2024. iskazuje Hrvatsku na 69,6%, a Poljsku na 65,9% prosjeka EU-a prema ukupnom inovacijskom učinku (European Commission, 2024a, 2024b). Sličan položaj obiju država na ovom pokazatelju argument je protiv tumačenja da razlike među primjerima proizlaze iz nacionalnog konteksta: ako bi se poslovne prakse Poljske i Hrvatske analizirane u ovom radu značajno razlikovale, to bi prije upućivalo na sektor, kapital ili međunarodnu potražnju nego na razliku u nacionalnim inovacijskim sustavima. Pokazatelj je, dakle, naknadni kontrolni kontekst za tumačenje regionalnog podrijetla, ne uzrok ili objašnjenje ranijih događaja te ne dopušta izdvajanje regionalnog učinka od sektora, kapitala ili međunarodne potražnje. Primjeri ne predstavljaju cijelu srednju i istočnu Europu.

3.3. POSTUPAK I VJERODOSTOJNOST

Jedinica analize jest dokumentirana praksa ili odluka u određenom vremenu. Postupak obuhvaća identifikaciju dokumenta i njegova izvornog informatora, izdvajanje navoda, dodjelu koda prema Tablici 1, usporedbu slučajeva i provjeru alternativnih tumačenja. Svaki je prikaz organiziran kroz okolnosti i praksu, interpretaciju te poveznicu s Marketingom 6.0 i ograničenje. Strateška fleksibilnost razmatra se dodatno, bez tvrdnje o formalnom otvorenom kodiranju ili zasićenosti tema.

Tablica 3 obuhvaća svih 28 kombinacija sedam dimenzija i četiriju poduzeća. I označava dokumentom potkrijepljenu interpretaciju, a ND nedovoljnu dokumentiranost, ne odsutnost prakse. Jedan navod može pripadati više kodova, ali ostaje jedan dokaz. Nepovoljan ishod ne potvrđuje prethodno promišljeno preuzimanje rizika. Tablica 4 odvojeno ispituje iskustvena obilježja.

Uspoređeni su izvori različitih izdavača i zabilježena njihova ovisnost: medijsko prenošenje priopćenja nije neovisna potvrda njegova sadržaja. Reutersovi izvještaji dodaju novinarski kontekst, dok se navodi anonimnih informatora i poduzeća tako i označavaju. Nisu provedeni neovisno dvostruko kodiranje, izračun slaganja koda ni potvrda kod poduzeća. Kodiranje je provedeno od jednog istraživača, pa oznake I i ND u Tablicama 3 i 4 treba čitati kao autorsko interpretativno tumačenje dostupnih dokumenata, a poglavlje 4 u cjelini kao ilustraciju analitičkog okvira, ne kao nezavisno provjerenu empirijsku analizu. Evidencija navoda, lokatora, kodova i granica omogućuje naknadni pregled, ali ne zamjenjuje neovisno kodiranje niti ga rad simulira.

Tablica 2. Korpus dokumenata i podrijetlo navoda

Primjer / kodovi	Dokumenti	Sadržaj i ovisnost izvora
CD Projekt C1–C3	C1: CD PROJEKT (n.d.); C2: CD PROJEKT (2020); C3: Reuters (2020)	Povijest; regulatorna objava; novinarski izvještaj s komentarom analitičara.
Booksy B1–B3	B1: Booksy Team (2021); B2: Musgrove (2021); B3: Booksy Team (2020)	Financiranje i ponuda; medijski prenesen iskaz poduzeća; konkretne funkcije.
Rimac R1–R3	R1: Porsche AG (2021b); R2: Porsche AG (2021a); R3: Reuters (2021)	Objave strateškog partnera; medijski izvještaj o istom događaju, ovisan o partnerovu iskazu.

Infobip I1–I4	I1: One Equity Partners (2020); I2: Infobip (n.d.); I3: Hu (2020); I4: Infobip Shift (n.d.)	Ulagatelj; preuzimanje Shifta; izvještaj s anonimnim informatorima; opis konferencije 2021.
------------------	---	---

Izvor: Popis uključenih dokumenata; potpuni zapisi i poveznice u literaturi. Oznake služe praćenju dokaza, ne ocjenjivanju izvora.

4. ILUSTRATIVNI PRIMJERI I USPOREDBA

4.1. CD PROJEKT: OBEĆANA I ISPORUČENA VRIJEDNOST

Korporativna povijest razlikuje grupu CD Projekt, osnovanu 1994., studio iz 2002. i GOG iz 2008. Opisuje lokalizaciju i distribuciju starijih igara bez zaštite DRM (CD PROJEKT, n.d.; C1). Regulatorna objava potvrđuje povlačenje Cyberpunka 2077 iz PlayStation Storea i povrate u prosincu 2020. (CD PROJEKT, 2020; C2). Reuters (2020; C3) izvješćuje o negativnim korisničkim ocjenama konzolnih inačica i prenosi analitičarev zahtjev za poboljšanjem komunikacije s igračima.

Lokalizacija i distribucija podupiru interpretaciju prilika, inovacije ponude i stvaranja vrijednosti. Nepovoljan događaj ograničava generalizaciju usmjerenosti na kupce: tržišno obećanje i njegova isporuka moraju se promatrati odvojeno. Analitičarev komentar nije mjerenje povjerenja.

Poveznica s Marketingom 6.0 ostaje nedokumentirana: imerzivnost igre nije dokaz imerzivne marketinške prakse. Razlike među platformama i kvaliteta izvedbe alternativna su objašnjenja korisničke reakcije, ne dokaz da je određena marketinška dimenzija uzrokovala poslovni ishod.

4.2. BOOKSY: PRILAGODBA USLUŽNOG SUSRETA

Booksy opisuje potrošačku aplikaciju za rezervacije i poslovnu aplikaciju za upravljanje uslugom, financiranje i spajanje s Versumom (Booksy Team, 2021; B1). Objavljeni prikaz funkcija iz 2020. navodi internetske bonove i automatske razmake između termina (Booksy Team, 2020; B3). Musgrove (2021; B2) prenosi navod poduzeća o širenju primjene rezervacija tijekom pandemije, uključujući posjete domovima za starije.

Funkcije podupiru interpretaciju prilagodbe potrebama, inovacije usluge i korisničke vrijednosti. B3 pruža konkretnije uporište za D5 od same objave financiranja. Širenje primjene može ilustrirati fleksibilnost, uz ograničenje da B2 prenosi zainteresirani iskaz.

Digitalna rezervacija povezuje se s fizičkom uslugom, ali imerzivna interakcija nije dokumentirana. Pandemijska ograničenja mogu objasniti promjenu primjene, pa je ne treba pripisati isključivo poduzetničkoj orijentaciji. Promotivni navodi o prihodima, lojalnosti ili zdravstvenim učincima funkcija nisu preuzeti kao dokaz učinkovitosti.

4.3. RIMAC: KOMBINIRANJE TEHNOLOŠKIH I PARTNERSKIH RESURSA

Porsche opisuje Rimčevu ponudu pogonskih i baterijskih sustava te sportskih automobila i povećanje svojeg udjela 2021. (Porsche AG, 2021b; R1). Srpanjska objava najavljuje Bugatti-

Rimac i povezivanje resursa (Porsche AG, 2021a; R2). Reuters (2021; R3) izvještava o istoj najavi na temelju Porscheovih navoda; dva izdavača ovdje ne znače dva neovisna informatora.

Prakse podupiru interpretaciju tehnološke prilike i mobilizacije partnerskih resursa. Promjena organizacije može ilustrirati fleksibilnost, ali plan suradnje nije dokaz njezina ostvarenog učinka. Poduzeće ima i potrošačku ponudu i ponudu poslovnim kupcima.

Visokotehnološko vozilo i najava partnerstva ne potvrđuju Marketing 6.0. Pristup kapitalu, tehnologiji i naslijeđenoj vrijednosti brenda mogu objasniti tržišne mogućnosti neovisno o marketinškoj orijentaciji. Korpus ne mjeri korisničke potrebe, imerzivno iskustvo ili povrat marketinških ulaganja.

4.4. INFOBIP: INFRASTRUKTURA I SUDJELOVANJE ZAJEDNICE

One Equity Partners (2020; I1) opisuje ulaganje i komunikacijsku platformu. Hu (2020; I3), pozivajući se na neimenovane informatore, izvještava o prvom vanjskom financiranju i planu američkog širenja. Infobipova objava povezuje preuzimanje Shifta s usmjerenjem prema programerima (Infobip, n.d.; I2).

Ponuda i akvizicija podupiru interpretaciju korisničkog segmenta i kombiniranja resursa. Stranica Shifta 2021. opisuje prijenos predavanja te udaljeni razgovor sa sudionicima uživo i postavljanje pitanja govornicima (Infobip Shift, n.d.; I4). To konkretizira ponuđeni način uključivanja zajednice.

I4 podupire ograničenu fizičko-digitalnu poveznicu i mogućnost suoblikovanja rasprave. Ipak, opis mogućnosti ne potvrđuje njezino korištenje ili doživljenu imerzivnost. Ponuda hibridnog događaja nije sama dokaz Marketinga 6.0. Kapital i potražnja za poslovnom komunikacijom ostaju alternativna objašnjenja širenja, bez procjene njihova relativnog učinka.

4.5. USPOREDNA SINTEZA

Tablica 3 uspoređuje dimenzije bez zbrajanja ili rangiranja. Najslabije je dokumentirana prethodna procjena rizika. Fleksibilnost je zasebno vidljiva kao mogućnost tumačenja prilagodbe primjene kod Booksya te promjene partnerskih i tržišnih odnosa kod Rimca i Infobipa.

Tablica 3. Usporedna matrica svih sedam dimenzija

Kod	CD Projekt	Booksy	Rimac	Infobip
D1	I: GOG (C1)	I: plan širenja (B1)	I: nova suradnja (R2)	I: programska zajednica (I2)
D2	I: lokalizacija (C1)	I: organizacija termina (B1)	I: električni pogon (R1)	I: poslovna komunikacija (I1)
D3	I: distribucija (C1)	I: prilagodba funkcija (B1/B3)	I: pogonski sustavi (R1)	I: platforma (I1)
D4	ND; posljedica ≠ procjena (C2)	ND	ND	ND

D5	I: lokalizacija; granica C2/C3 (C1)	I: prilagodba terminima (B3)	ND: nema podataka o potrebama kupaca	I: ponuđeno sudjelovanje (I2/I4)
D6	I: korištenje postojećeg kataloga (C1)	I: povezivanje s Versumom (B1)	I: partnerski resursi (R1–R2)	I: mreža i konferencija (I1–I2)
D7	I: dostupnost igara (C1)	I: rezervacija i upravljanje (B1/B3)	I: tehnološka ponuda (R1)	I: povezivanje kanala (I1)

Izvor: Interpretacija dokumenata iz Tablice 2. I = dokumentom potkrijepljena interpretacija; ND = nedovoljno dokumentirano. Kodovi su definirani u Tablici 1. Matrica ne mjeri intenzitet, uspješnost ili uzročnost.

Booksy ilustrira funkcionalni kontinuitet rezervacije i usluge, a Shift ponuđeno povezivanje fizičkih i udaljenih sudionika. Ostali izvori ne daju dovoljno podataka o povezanom iskustvu. Ni u jednom primjeru korpus ne potvrđuje imerzivnu marketinšku interakciju (Tablica 4). Djelomična poveznica zato nije potvrda cjelovite konvergencije niti odsutnost dokaza znači odsutnost prakse.

Dva obrasca u tablicama zaslužuju posebnu pažnju. Prvo, D4 (promišljeno preuzimanje rizika) jedina je dimenzija bez potvrđene interpretacije kod bilo kojeg poduzeća (Tablica 3); to je dosljedno stime da poduzeća u javno dostupnim dokumentima rijetko iznose prethodne procjene rizika, neovisno o tome jesu li takve procjene stvarno provedene. Nedokumentiranost D4 tako je vjerojatnije obilježje dostupne građe nego dokaz da procjena rizika nije postojala, što ograničava zaključke o toj dimenziji specifično, dok preostale dimenzije nisu podjednako pogođene ovim tipom pristranosti izvora. Drugo, Infobip je jedini primjer s potvrđenom poveznicom u sve tri kategorije Tablice 4 barem djelomično (fizičko-digitalni kontinuitet i suoblikovanje), što je moguće povezati s njegovom komunikacijskom djelatnošću kao takvom, a ne nužno s poduzetničko-marketinškom orijentacijom; sektorska priroda poslovanja ovdje je konkurentno objašnjenje koje korpus ne omogućuje razdvojiti od marketinške prakse.

Tablica 4. Provjera obilježja povezanih s Marketingom 6.0

Primjer	Fizičko-digitalni kontinuitet	Imerzivna marketinška interakcija	Suoblikovanje iskustva
CD Projekt	ND (C1–C3)	ND; igra nije dokaz marketinga	ND
Booksy	I: rezervacija → usluga (B1/B3)	ND	ND; uporaba ≠ suoblikovanje
Rimac	ND (R1–R3)	ND; vozilo nije dokaz iskustvenog marketinga	ND
Infobip	I: povezano sudjelovanje uživo i na daljinu (I4)	ND; hibridnost nije dokaz imerzivnosti	I: ponuđena pitanja i razgovor (I4); uporaba nije mjerena

Izvor: Autorski analitički filter iz poglavlja 2.2 primijenjen na korpus iz Tablice 2. I = ograničena interpretativna poveznica; ND = nedovoljno dokumentirano. Nije validirana ljestvica Marketinga 6.0.

5. RASPRAVA I ISTRAŽIVAČKE PROPOZICIJE

Razlikovanje dimenzija i posredničkih sposobnosti slijedi prethodna istraživanja (Sadiku-Dushi et al., 2019; Sahu & Panda, 2024; Zahara et al., 2023). Predloženi okvir dodaje provjeru iskustvenog sadržaja i podrijetla dokaza. Tako omogućuje istraživanje poveznica bez unaprijed pretpostavljene konvergencije.

Sektorske razlike u kupnji, posredovanju i kapitalnim zahtjevima konkuriraju objašnjenju marketinškom orijentacijom. Uspjeh može povećati resurse i medijsku vidljivost, pa smjer odnosa ostaje otvoren. Nepovoljan događaj kod Cyberpunka ne zamjenjuje uzorak neuspješnih poduzeća. Praktično, tehnologiju treba povezati s korisničkom potrebom; učinkovitost te preporuke ovdje nije ispitana.

5.1. PROPOZICIJE ZA BUDUĆU PROVJERU

P1 – Korisnički odnos. Poduzeća s izraženijom usmjerenošću na prilike i intenzivnom usmjerenošću na kupce (D2, D5) razvijaju oblike isporuke vrijednosti koji su prilagođeniji promjeni korisničke potrebe u kratkom roku (primjerice promjenu primjene ili distribucijskog kanala), nego poduzeća kod kojih te dimenzije nisu dokumentirane; mehanizam je brža povratna informacija od korisnika prema ponudi. Odnos se očekuje uz kontrolu sektora, zemlje, veličine, starosti i financiranja. Polazište su različite prakse u Tablici 3, a teorijska osnova razlikovanje orijentacija kod Jonesa i Rowley (2011). Provjera zahtijeva više usporedivih poduzeća unutar sektora, mjerenje brzine i opsega prilagodbe ponude kao ishoda; oznake B2B i B2C nisu dovoljne za objašnjenje razlika.

P2 – Oblikovanje iskustva. Veza poduzetničkih marketinških praksi i doživljene imerzivnosti nije izravna, već je posredovana time je li korisniku ponuđena mogućnost utjecaja na sadržaj ili tijek iskustva (suoblikovanje), a ne samom ponudom fizičko-digitalnog kontinuiteta: poduzeća koja dokumentiraju samo funkcionalnu poveznicu (npr. rezervacija povezana s uslugom) ne trebaju pri tome ostvarivati veću doživljenu imerzivnost od onih bez takve poveznice, dok se veća doživljena imerzivnost očekuje kod poduzeća koja dokumentiraju stvarnu mogućnost suoblikovanja. Polazište je razlika između ponuđene interakcije i nedokumentirane imerzivnosti u Tablici 4, gdje Infobipov primjer ponuđenog suoblikovanja (I4) ilustrira ovu razliku od Booksyjeva primjera funkcionalnog kontinuiteta bez suoblikovanja. Teorijsku poveznicu daju Whalen i Akaka (2016) te Kotler et al. (2023). Potrebni su podaci poduzeća i korisnika o doživljenoj prisutnosti, te usporedba funkcionalno sličnih rješenja različitog iskustvenog sadržaja kako bi se razdvojio učinak suoblikovanja od same digitalne funkcionalnosti.

P3 – Fleksibilnost. Povezanost strateške fleksibilnosti i poslovnih rezultata ovisi o promjenama resursnih i tržišnih ograničenja. Prilagodbe iz poglavlja 4.2–4.4 otvaraju to pitanje, a nalazi Saha i Pande (2024) o inovaciji u nestabilnom okruženju pružaju teorijski oslonac. Potrebna su mjerenja prije i nakon promjene uz usporednu skupinu. Ne tvrdi se dokazan porast važnosti fleksibilnosti kroz razvojne faze.

5.2. OPERACIONALIZACIJA I USPOREDBE DRŽAVA

Buduće istraživanje treba usporediti postojeće ljestvice, uključujući Yadav et al. (2024), te provesti kognitivne intervjue i pilot. Usmjerenost na prilike može obuhvatiti traženje nezadovoljenih potreba, a rizik prethodnu procjenu gubitka i ograničavanje izloženosti. Fleksibilnost se mjeri zasebno. Tablica 1 nije gotova anketna ljestvica.

Ishodi mogu obuhvatiti zadržavanje korisnika i trošak njihova stjecanja, a iskustvo doživljaj prisutnosti, interaktivnost i kontinuitet, odvojeno od zadovoljstva. Podaci korisnika i poslovni pokazatelji trebaju dopuniti menadžerske procjene. Uzorak se određuje analizom statističke snage. Usporedbe Poljske, Hrvatske i drugih država trebaju uskladiti sektore i razvojnu dob, uključiti manje uspješne pothvate te provjeriti jezičnu i mjernu ekvivalentnost. Longitudinalni podaci potrebni su za ispitivanje promjena.

6. OGRANIČENJA I ZAKLJUČAK

Trinaest dokumenata o četirima javno vidljivim poduzećima čini malen, namjerno odabran i nejednak korpus. Medijski izvještaji ne uklanjaju ovisnost o iskazima poduzeća i ulagača. Nisu dostupni interni planovi, proračuni, prethodne procjene rizika ni korisnička mjerenja. Dio znanstvenih izvora razmotren je samo putem dostupnih sažetaka. Izostaju potpuna metodološka procjena literature, neovisno kodiranje i longitudinalno praćenje. Heterogenost i pristranost prema uspješnim primjerima ograničavaju prenosivost zaključaka.

Konceptualno ograničenje dodatno se odnosi na sam odabir primjera: teorijski okvir poduzetničkog marketinga izvorno opisuje mala i srednja poduzeća u uvjetima resursne oskudice, dok su CD Projekt, Booksy, Rimac i Infobip u analiziranom razdoblju već međunarodno vidljivi i dobro financirani akteri. Rad zaključke stoga ograničava na primjenu poduzetničko-marketinških dimenzija na dokumentirane prakse rasta i partnerstva ovih poduzeća, a ne na poduzetnički marketing malih i srednjih poduzeća općenito; prenošenje nalaza na tipičan MSP zahtijeva zaseban korpus poduzeća u ranoj razvojnoj fazi.

Doprinos je okvir koji povezuje praksu, dokaz i domet zaključka. Sedam dimenzija povezano je s dokumentima, a iskustvo se provjerava zasebno. Booksy i Shift nude djelomične fizičko-digitalne poveznice, bez potvrđene imerzivnosti. Fleksibilnost ostaje zasebna tema, a propozicije istraživačka agenda. Usporedba ne dokazuje univerzalne učinke poslovnog modela ili regionalnog podrijetla.

IZJAVA O KORIŠTENJU GENERATIVNE UMJETNE INTELIGENCIJE

Pri reviziji rukopisa korišten je ChatGPT (OpenAI) za usporedbu recenzentskih primjedbi, pomoć u pretraživanju i provjeri izvora, preoblikovanje teorije i metodologije, pripremu analitičkih matrica te sadržajno i jezično uređivanje. Alat nije izvor empirijskih podataka niti neovisni ljudski koder. Konačno odobrenje interpretacija i teksta odgovornost je autora.

REFERENCE

1. Booksy Team. (2020, 13. prosinca). *Salon essentials – 2020's most effective salon software features*. Booksy. <https://biz.booksy.com/en-gb/blog/salon-essentials-2020-s-most-effective-salon-software-features-v>
2. Booksy Team. (2021, 26. siječnja). *Booksy announces \$70 million in funding round and merger with Versum*. Booksy. <https://biz.booksy.com/en-gb/blog/booksy-announces-70-million-in-funding-round-and-merger-with-versum>
3. Bowen, G. A. (2009). Document analysis as a qualitative research method. *Qualitative Research Journal*, 9(2), 27–40. <https://doi.org/10.3316/QRJ0902027>

4. CD PROJEKT. (n.d.). *History*. Preuzeto 8. rujna 2026. s <https://www.cdprojekt.com/en/capital-group/history/>
5. CD PROJEKT. (2020, 18. prosinca). *Current report no. 66/2020: Temporary suspension of the availability of Cyberpunk 2077 on PlayStation Store*. <https://www.cdprojekt.com/en/investors/regulatory-announcements/current-report-no-66-2020/>
6. European Commission. (2024a). *European Innovation Scoreboard 2024: Country profile Croatia*. https://ec.europa.eu/assets/rtd/eis/2024/ec_rtd_eis-country-profile-hr.pdf
7. European Commission. (2024b). *European Innovation Scoreboard 2024: Country profile Poland*. https://ec.europa.eu/assets/rtd/eis/2024/ec_rtd_eis-country-profile-pl.pdf
8. Hu, K. (2020, 30. srpnja). *Exclusive: European software startup Infobip raises over \$200 million in Series A funding – sources*. Reuters. <https://www.reuters.com/article/business/exclusive-european-software-startup-infobip-raises-over-200-million-in-series-idUSKCN24V0BZ/>
9. Infobip. (n.d.). *Infobip acquires Europe's largest tech conference Shift*. <https://shift.infobip.com/us/infobip-acquires-shift/>
10. Infobip Shift. (n.d.). *Infobip Shift conference 2021*. <https://shift.infobip.com/europe/zadar-2021/>
11. Jones, R., & Rowley, J. (2011). Entrepreneurial marketing in small businesses: A conceptual exploration. *International Small Business Journal*, 29(1), 25–36. <https://doi.org/10.1177/0266242610369743>
12. Kotler, P., Kartajaya, H., & Setiawan, I. (2010). *Marketing 3.0: From products to customers to the human spirit*. Wiley.
13. Kotler, P., Kartajaya, H., & Setiawan, I. (2023). *Marketing 6.0: The future is immersive*. Wiley.
14. Morris, M. H., Schindehutte, M., & LaForge, R. W. (2002). Entrepreneurial marketing: A construct for integrating emerging entrepreneurship and marketing perspectives. *Journal of Marketing Theory and Practice*, 10(4), 1–19. <https://doi.org/10.1080/10696679.2002.11501922>
15. Musgrove, A. (2021, 27. siječnja). *Polish appointment app Booksy raises \$70 million to expand across Europe and US*. Tech.eu. <https://tech.eu/2021/01/27/booksy-series-c/>
16. One Equity Partners. (2020, 30. srpnja). *One Equity Partners to make strategic investment in Infobip, a global "Communications Platform as a Service" leader*. <https://www.oneequity.com/news/one-equity-partners-to-make-strategic-investment-in-infobip-a-global-communications-platform-as-a-service-leader/>
17. Porsche AG. (2021a, 5. srpnja). *Bugatti-Rimac combines the genes of strong brands*. Porsche Newsroom. <https://newsroom.porsche.com/en/2021/company/porsche-bugatti-rimac-joint-venture-25000.html>
18. Porsche AG. (2021b, 8. ožujka). *Porsche increases stake in Rimac Automobili to 24 per cent*. Porsche Newsroom. <https://newsroom.porsche.com/en/2021/company/porsche-increases-stake-rimac-automobili-24-per-cent-23825.html>
19. Reuters. (2020, 14. prosinca). *CD Projekt shares tank on bad Cyberpunk console reviews, refund reports*. <https://www.reuters.com/technology/cd-projekt-shares-tank-bad-cyberpunk-console-reviews-refund-reports-2020-12-14/>
20. Reuters. (2021, 5. srpnja). *Porsche AG, Croatia's Rimac set up JV involving VW's Bugatti brand*. <https://www.reuters.com/business/autos-transportation/porsche-ag-croatias-rimac-set-up-jv-involving-vws-bugatti-brand-2021-07-05/>
21. Sadiku-Dushi, N., Dana, L.-P., & Ramadani, V. (2019). Entrepreneurial marketing dimensions and SMEs performance. *Journal of Business Research*, 100, 86–99. <https://doi.org/10.1016/j.jbusres.2019.03.025>

22. Sahu, C. K., & Panda, R. K. (2024). Entrepreneurial marketing practices and manufacturing venture performance during a pandemic: The mediating role of innovation. *Journal of Small Business and Enterprise Development*, 31(5), 929–949. <https://doi.org/10.1108/JSBED-07-2022-0312>
23. Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333–339. <https://doi.org/10.1016/j.jbusres.2019.07.039>
24. Whalen, P. S., & Akaka, M. A. (2016). A dynamic market conceptualization for entrepreneurial marketing: The co-creation of opportunities. *Journal of Strategic Marketing*, 24(1), 61–75. <https://doi.org/10.1080/0965254X.2015.1035040>
25. Yadav, A., Paul, J., Bansal, S., & Talan, A. (2024). Developing and validating a scale for entrepreneurial marketing orientations: EMICO framework and its impact on business performance in startups. *Journal of Organizational Change Management*, 37(7), 1655–1687. <https://doi.org/10.1108/JOCM-11-2023-0461>
26. Zahara, Z., Ikhsan, Santi, I. N., & Farid. (2023). Entrepreneurial marketing and marketing performance through digital marketing capabilities of SMEs in post-pandemic recovery. *Cogent Business & Management*, 10(2), Article 2204592. <https://doi.org/10.1080/23311975.2023.2204592>

EMPLOYER BRANDING AS A STRATEGIC MARKETING TOOL FOR TALENT ATTRACTION AND EMPLOYEE ENGAGEMENT IN THE DIGITAL ENVIRONMENT

NINA MINOV

MIL Sistemika d.o.o.

Na Brežini 12, 1231 Ljubljana Črnuče, Slovenia

nina.minov@milsistemika.com

MIHA MARIČ

Faculty of Organizational Sciences

University of Maribor

Kidričeva cesta 55a, 4000 Kranj, Slovenia

miha.maric@um.si

ABSTRACT

This paper explores employees' perceptions of employer branding in relation to talent attraction and employee commitment in the digital environment. The theoretical background shows that an employer brand represents the organization's reputation, internal environment, employee experience and digital communication. A qualitative case study was conducted using an open-ended questionnaire completed by ten employees from one organization. Results show that respondents perceive their employer organization as flexible, professional, supportive and people-oriented. Important employer brand aspects in their view include interesting and important technical tasks, modern technology and tools, trust between colleagues, continuous development, positive social relationships within teams and work flexibility. The findings suggest that authentic employer branding means matching the digital external communication to the actual employee experience. Respondents perceived such alignment as relevant to the organization's employer reputation and employee commitment and potentially to its attractiveness to suitable candidates. The findings also suggest that employees may be willing to participate as employer brand ambassadors.

KEYWORDS: employer branding, talent attraction, marketing, employee engagement, digital communication

1. INTRODUCTION

Nowadays companies no longer compete only for customers, market share and technical advantage, but also for qualified employees. As jobs become more knowledge- and digitally based, the challenge for companies is to attract and keep qualified employees. In addition to good salaries and job security, today's workers are also looking for interesting opportunities, flexibility, meaningful work, personal and professional growth, a specific corporate culture and a certain reputation as an employer. Therefore, the concept of employer branding, which

combines human resources, communication and marketing activities of a company, has become an important issue.

Reis et al. (2021) define employer branding as a strategic tool for communicating organizational identity, values, culture, and employee value proposition. Furthermore, Reis et al. (2021) emphasize that employer branding can be understood as both an HR and marketing activity. Employer branding is not only a question of recruiting campaigns and job advertisements. It is so much more. It is also about how the organisation is presented, how it is experienced by its employees, and how this experience is communicated to them, both internally and externally. Employer branding is therefore strongly linked to reputation and employee experience, because employees are the best ambassadors for the company.

In today's world, where digital tools are playing an increasingly important role and companies are increasingly competing for skilled workers, attracting employees through digital channels has become increasingly important. Because people encounter vast amounts of information on social media, employee ambassadors can provide credible accounts of organizational life. Such accounts may make the company's digital presence appear more credible to potential employees.

It has become increasingly common for candidates to make initial assumptions about a particular company based on information available on social media (Thang & Trang, 2024). Thus, the company's digital presence is becoming increasingly important for attracting talent. Thang and Trang (2024) state that employer branding, organizational image and reputation are related to candidates' intention to apply.

The purpose of this work is to analyse the concept of employer branding as a marketing tool for talent attraction and employee engagement in the digital environment. The paper presents the results of research on how employees perceive the employer brand of a selected organization, what aspects they find most attractive and credible, how they evaluate the employer brand as communicated digitally, and whether and how employer branding is related to employee engagement and willingness to recommend the organization to other people as an employer.

The research was guided by the following five research questions:

- *RQ1: How do employees perceive the organization's employer brand?*
- *RQ2: Which elements of the employer brand do employees perceive as most attractive and credible?*
- *RQ3: How do employees perceive the role of digital communication channels in the organization's employer brand?*
- *RQ4: To what extent do employees perceive external employer branding communication as aligned with their actual employee experience?*
- *RQ5: How do employees perceive the relationship between employer branding and employee engagement, organizational commitment, and willingness to recommend the organization as an employer?*

2. THEORY

The notion of employer branding has entered both the talent management and strategic communication areas (Thang & Trang, 2024; Reis et al., 2021). Employer branding allows a

company to build an image of itself as an attractive employer, especially where labour markets are highly competitive (Reis et al., 2021). In this respect, employer branding can also be regarded as a marketing activity directed at a specific group: employees (both current and potential).

Employer branding is manifested in different ways in the digital environment. In the modern world, it increasingly relies on different digital channels of communication and interaction, such as professional social networks (such as LinkedIn), other social media channels, organisational websites, online review sites or employee-generated content (Reis et al., 2021; Thang & Trang, 2024). In relation to employer branding and the digital environment, Thang and Trang (2024) argue that an organisation's image, reputation and candidates' intention to apply are all strengthened by the organisation's social media presence. This shows that digital communication serves as far more than just a complementary function; it acts as a vital channel for potential applicants to assess potential employers.

A central requirement is that the employer branding message is consistent with the lived experience of real employees. Barbulescu et al. (2024) emphasize the importance of internal employer branding for engaging and retaining employees. Therefore, employer branding is shaped not only by intended marketing communication but also by leadership behaviour, organizational events, flexibility, communication, and organizational culture. Internal communication is also an important part in the context of employer branding. Santos et al. (2023) highlight that internal communication can strengthen employer branding by helping employees understand organizational identity, values, and purpose. This suggests that workers are not just receivers of employer branding, but also active participants in the employer brand, especially in the digital context, where employees can share their experiences through professional social networks, social media, informal recommendations, and digital communication and thereby become company ambassadors.

There is also a significant relationship between employer branding and employee engagement. Park and Kim (2024) point out that internal branding can enhance work engagement by enabling employees to align with organizational values. This means that employer branding can strengthen engagement when employees feel they belong to the organization and that their work is meaningful. The employer branding concept is also related to employee retention and commitment. Onur et al. (2024) discovered that employer brand attractiveness contributes to organizational commitment, and it is related to turnover intention. In a similar way, Alzaid and Dukhaykh (2023) reveal that employer branding is positively associated with employee retention. This suggests that employer branding should not only be considered as a tool for recruitment purposes, but also as a strategic human resource practice that may support long-term commitment.

Current employees are also among the most trustworthy sources of communication concerning employer branding for external audiences. Thao et al. (2024) suggest that employees' attitudes can influence employer branding because satisfied employees enhance organizational reputation. Dassler et al. (2022) argue that employer attractiveness should not be examined only from the perspective of candidates, because current employees also shape and maintain the employer brand.

Another significant feature of employer branding relates to generational shifts. Younger generations and especially Gen Z often assess employers based on their authenticity, development opportunities, meaningful work, responsibility, digital transparency and carbon

footprint. Rzemieniak and Wawer (2021) argue that sustainable employer branding is important especially for Generation Z. Iyer et al. (2026) point out that employer branding for younger generations should focus on authenticity, career development, meaningful work, and transparent digital communication. Therefore, digital platforms such as LinkedIn are significant tools for employer branding because they enable companies to display their expertise, organizational culture, employees' stories, achievements, and development opportunities (Ashraf et al., 2025). In this way, digital employer branding becomes part of a broader strategic marketing approach. Based on the theoretical framework, employer branding should be considered from both external and internal aspects. Externally, it has a role in attracting human resources and building up organizational attractiveness, and internally it is associated with employees' perceived engagement, commitment, satisfaction, and intentions.

Foundational research links employer branding to brand management, organizational identity and employer attractiveness (Ambler & Barrow, 1996; Backhaus & Tikoo, 2004). Existing studies largely focus on attraction, engagement or retention, leaving less evidence on employees' perceptions of alignment between lived experience and digital communication. This case addresses that gap in one technology organization by framing authenticity as internal-external alignment.

3. METHODOLOGY

To answer the research questions, we used a qualitative case study research design concentrating on employer branding within the selected technology organization. Qualitative research methods were best suited to the purpose of the research, which is to discover how employees see the company as an employer and how they perceive employer branding in relation to their own experience and engagement as well as digital communication.

Data were gathered from a short, semi-structured questionnaire with ten open-ended questions. The questionnaire focused on employees' view of the organisation as an employer; the most attractive parts of the employer brand; internal and external communication; digital visibility; authenticity of employer branding; employees' engagement; and willingness to recommend the organization as an employer. The sample comprised of ten employees with various roles in the company from employees to managers, selected to capture diverse internal perspectives. Written responses were collected in the beginning of June 2026. Interviews were conducted by the HR manager of the company. As employees are an important source of employer brand credibility, the questionnaire also asked whether employees see themselves as potential ambassadors of the employer brand.

We collected the written responses and analysed them thematically. The responses were read in full, assigned descriptive codes, and grouped into recurring themes. The themes were then compared across respondents and mapped to the five research questions. The resulting themes were organizational attractiveness, employee value proposition, internal communication, digital employer branding, authenticity, engagement, and improvement opportunities.

4. RESULTS

4.1. EMPLOYER BRAND PERCEPTION (RQ1)

According to the respondents, the company was generally described as a positive employer. The words used to describe the company as an employer included dynamic, interesting, flexible, employee-friendly, relaxed and supportive. Some respondents mentioned that the organization is characterized by interesting tasks and opportunities to grow, and a good work environment.

The combination of professionalism and informality is also a common theme in the answers. Employees did not describe the company as stiff or corporate. Instead, they felt that they could contribute their ideas, communicate with colleagues and managers and take part in interesting projects. This suggests that the internal employer brand is associated with flexibility, trust, relationships and professional challenge.

At the same time, employees also described the company as demanding. The company has many opportunities and advantages, but it also expects employees to take responsibility, adapt to change and perform well. This suggests that employer branding should not present only a relaxed and flexible company, but also a challenging one that suits those who are motivated by complex work.

4.2. ATTRACTIVE AND CREDIBLE EMPLOYER BRAND ELEMENTS (RQ2)

The most frequently mentioned aspects of working in the organization are flexibility, interesting work, modern technology, good relationships and balance between work and private life. Respondents mentioned flexible working hours, remote work and a relaxed atmosphere, as well as the close relationships possible in a smaller company. Others emphasized the work itself, particularly interesting and technically demanding projects. This is also important for technical talent, as many candidates look for modern technology, challenging tasks, and the opportunity to solve complex issues.

Based on this, the Employer Value Proposition could emphasize three main pillars: flexibility, meaningful technical challenges and team culture, which is both supportive and professional. These are the values that employees perceive as credible because they experience them in their daily work.

Employees associate the organization with such values as trust, reliability, fairness, teamwork, flexibility, professionalism, responsibility and care for employees. Many respondents particularly emphasized trust and fair play. Some mentioned that management is accessible and that the company is generally good at keeping its promises to employees. Respondents also mentioned teamwork and collegiality several times. Thus, this company can be considered supportive of employees' social needs.

4.3. DIGITAL COMMUNICATION (RQ3)

The analysis of internal communication has shown contradictory results. The employees mentioned that the company communicates its culture well, especially through management behaviour and daily interactions, yet many employees also identified areas for improvement in internal communication. Respondents mentioned slow communication, unclear information, silo mentality between work units, misunderstandings and some information gaps. This

suggests that although positive cultural values are present, they are not communicated consistently enough. This is relevant to employer branding because external communication alone cannot create a strong employer brand. If there are communication shortcomings internally, this may reduce the perceived credibility of external employer branding.

In relation to the digital presence, most respondents mainly noticed the organization's activity on LinkedIn, while they had less awareness of its other digital channels. Some respondents do not follow digital channels actively; some believe that LinkedIn is the main channel and that the website and other social media channels could be used better. This suggests that the organization currently has a fundamental digital employer branding presence, but not a fully developed digital strategy. One key finding is that employees believe the organization does interesting work, which is relevant from a technological point of view, but potential candidates might not be sufficiently aware of that. Some respondents emphasized that people outside the company may not see how interesting its projects are. In other words, the employer branding is perceived positively internally, but it is not yet fully reflected in external communication, particularly through digital channels.

4.4. ALIGNMENT AND AUTHENTICITY (RQ4)

Regarding how realistic the presentation of the organization as an employer is, most respondents considered it fairly realistic. Employees did not describe the external presentation as false, but some think that the company is, like many others, presenting itself somewhat more favourably than their daily experience suggests. The discrepancies mentioned by employees concerned the internal organization, processes, planning, time pressures, and structure. This does not mean that the presentation of the organization as an employer is false, but it should be true and balanced. The correspondence between the external image and the employee experience is, therefore, generally positive, although not complete. Employees consistently associated their positive experience with flexibility, team spirit, interesting work, and learning opportunities. The areas where improvements are needed are communication, planning, and processes.

4.5. ENGAGEMENT AND RECOMMENDATION (RQ5)

In the engagement questions, the most frequently mentioned engagement factors were flexibility, working from home, interesting projects, modern technology, events, team cooperation, learning opportunities, and the overall good climate. Respondents also identified their work content, opportunities to present ideas, and meaningful work as important engagement factors. Additionally, internal events, informal social gatherings, product presentations, and cooperation with colleagues were mentioned as engagement factors. It is also notable that most respondents said they would recommend the organization as a workplace, some noted that they had already done so, while others added that it depends on the fit between the person, position, and organization. This suggests that employees may be willing to take part in employer-branding efforts and that recommendations depend on person-organization fit.

4.6. IMPROVEMENT OPPORTUNITIES

The improvement opportunities mentioned most often by respondents are stronger external communication aimed at potential candidates, better presentation of technological projects, improvements in internal processes, better planning, better organization of work, and better

communication internally. They thought that the company should communicate more clearly what it does, what problems it solves, and why the work is interesting and meaningful.

5. DISCUSSION

The findings suggest that employer branding is perceived not only as an external marketing activity but also as an important human resource and organizational development instrument. It was evident in the questionnaire responses that there are several employer brand elements that the organization already has: flexibility, interesting technical projects, access to modern technology, good relationships within teams, trust in leadership, opportunities for development, a good team culture. These are all elements that were perceived as relevant to employer attractiveness and employee engagement.

The first research question aimed to find out how employees perceive the organization as an employer. The questionnaire responses showed that the respondents perceive the employer brand to be positive, flexible, professional, and people-focused. The organization was seen as offering flexibility and autonomy, interesting work and good relationships, while demanding responsibility and adaptability at the same time.

The second research question aimed to find out which elements of the employer brand are most attractive and how credible the organization's employer brand elements are to employees. The analysis results showed that the most relevant employer brand elements for the employees are flexibility, interesting technical work, good team culture, opportunities for development and growth, as well as trust. These are credible elements because all the respondents could observe them during their daily work experience.

In the third research question, we examined how employees perceive digital communication in relation to the employer brand. The results showed that respondents associated digital channels with the employer brand, but there is still room for further development. LinkedIn was the only channel that was familiar to the respondents, but the findings suggest that the company could use digital communication for employer branding more, particularly by talking more about its projects, technologies, team culture and employee experiences.

The fourth research question investigated the extent of alignment between external employer branding and employees' work experience. The analysis results showed generally positive, although incomplete alignment. Respondents perceive the external employer brand as authentic, but they point out that the organization has shortcomings in internal communication and project organization. These issues need to be addressed to support the long-term credibility of the employer brand.

In the fifth research question, we examined employees' perceived relationship between the employer brand and employee engagement. The findings suggest that respondents perceive a positive relationship between the employer brand and employee engagement. Respondents mentioned that they are motivated by the flexibility of work, interesting projects, opportunities for development and growth, internal events and activities, as well as good relationships within the team. According to the questionnaire responses, they are quite willing to recommend the organization as an employer to acquaintances, suggesting that they could also be potential ambassadors of employer branding.

The findings align with prior work on the employee value proposition, employee-based employer attractiveness, internal communication and authenticity (Reis et al., 2021; Dassler et al., 2022; Santos et al., 2023; Thao et al., 2024). Unlike studies reporting relationships with engagement, commitment and application intentions (Park & Kim, 2024; Onur et al., 2024; Thang & Trang, 2024), this case does not test those effects but shows how employees perceive them. Its theoretical contribution is to frame authenticity as alignment between internal experience and external digital communication.

Overall, the organization appears to have positive potential for employer branding internally, but that is currently not sufficiently reflected in digital communication. Employees feel that the organization does technically interesting work that could be relevant to job seekers, but this is not visible enough externally. Therefore, there is an opportunity for the organization to strengthen the employer branding in digital communication with more visible and consistent storytelling, particularly on LinkedIn, company website, and other relevant channels.

The employer branding should be communicated to target groups through authentic content reflecting the employee experience. Examples include stories about employees and their work, insights into projects, the development of new technologies, internal learning activities, team events and activities, remote working culture as well as examples of technical issues that employees face. The employer brand should not, however, be limited to external communication; it should also be reflected inside the organization. The organization needs to improve communication, planning and work organization to support the credibility of the employer brand.

6. CONCLUSION

According to the analysis, the company is perceived by its employees as a good employer. The key elements of the employer brand of the organization are, according to employees, flexibility, trust in the employer, interesting work with new technologies, teamwork and opportunities for personal development. Most respondents said that they would recommend the organization to other people as an attractive employer, suggesting that they perceive the internal employer brand as credible and attractive.

The findings suggest that clearer digital employer-branding communication could support the organization's positioning among potential candidates. In addition, it is important to strengthen the internal and external communication of the organizational culture, employee experiences, opportunities for personal development and learning, as well as the atmosphere in the team, to communicate the employer brand more clearly to potential candidates.

Employer branding can be viewed as a marketing and HR tool, with a strategic purpose, which aims to connect external recruitment and internal employee engagement. When the external employer image aligns with the experiences of the employees and with the organizational goals, the findings suggest that this alignment may strengthen the perceived employer brand and may be relevant to candidate fit and employee commitment; effects on attraction and long-term organizational capacity require further testing.

The case study showed that the employees of the organization are central to the credibility of the employer brand. Their perceptions of work and their willingness to recommend the company to acquaintances may be relevant to potential job seekers' perceptions. This suggests

that the employer branding is not only recruitment communication, but continuous strategic and marketing work that connects the internal organizational culture and employee experience to external digital communication and talent management.

The main limitation of the research is its qualitative design and small sample. The respondents were employees of the case organization; therefore, the findings provide insight only into perceptions within this organization. Thus, we cannot generalize our findings. The study did not directly test changes in talent attraction, employee commitment, engagement, or organizational capacity. In future studies, the sample could be larger, and qualitative research could be combined with quantitative measures of engagement and employer attractiveness.

REFERENCES

1. Alzaid, D., & Dukhaykh, S. (2023). Employer branding and employee retention in the banking sector in Saudi Arabia: Mediating effect of relational psychological contracts. *Sustainability*, 15(7), Article 6115. <https://doi.org/10.3390/su15076115>
2. Ambler, T., & Barrow, S. (1996). The employer brand. *Journal of Brand Management*, 4, 185–206. <https://doi.org/10.1057/bm.1996.42>
3. Ashraf, R., Hitam, N. A., Khan, M. M. S., Naithani, P., Khmour, N., Badreddine, S., & Albeshr, M. (2025). Leveraging LinkedIn as a digital platform for employer branding: Evidence from the UAE hotel industry. *Journal of Theoretical and Applied Electronic Commerce Research*, 20(4), Article 316. <https://doi.org/10.3390/jtaer20040316>
4. Backhaus, K., & Tikoo, S. (2004). Conceptualizing and researching employer branding. *Career Development International*, 9(5), 501–517. <https://doi.org/10.1108/13620430410550754>
5. Barbulescu, F.-M., Vasiliuță-Ștefănescu, M., Stoicov, I., Coman, C., & Coman, E. (2024). Strategic management of internal employer branding – guerilla strategies to engage and retain top employees in a challenging workforce environment. *Frontiers in Communication*, 9, Article 1402125. <https://doi.org/10.3389/fcomm.2024.1402125>
6. Dassler, A., Khapova, S. N., Lysova, E. I., & Korotov, K. (2022). Employer attractiveness from an employee perspective: A systematic literature review. *Frontiers in Psychology*, 13, Article 858217. <https://doi.org/10.3389/fpsyg.2022.858217>
7. Iyer, K. V., K., A., Al Hajj, R., & Saadouli, N. (2026). Decoding Gen Z talent attraction: How employer branding shapes media sector employment intentions. *Frontiers in Communication*, 10, Article 1670231. <https://doi.org/10.3389/fcomm.2025.1670231>
8. Onur, N., Celik Yetim, A., Guven, Y., Gozen, E., Ozilhan Ozbey, D., & Coskun Degirmen, G. (2024). Employer brand attractiveness and organizational commitment: The moderating role of organizational support. *Sustainability*, 16(13), Article 5394. <https://doi.org/10.3390/su16135394>
9. Park, J., & Kim, J. (2024). Exploring the relationships among internal branding, work engagement, and turnover intention in public sports organizations after the pandemic. *Sustainability*, 16(3), Article 1342. <https://doi.org/10.3390/su16031342>
10. Pološki Vokić, N., Tkalac Verčić, A., & Sinčić Čorić, D. (2023). Strategic internal communication for effective internal employer branding. *Baltic Journal of Management*, 18(1), 19–33. <https://doi.org/10.1108/BJM-02-2022-0070>
11. Reis, I., Sousa, M. J., & Dionísio, A. (2021). Employer branding as a talent management tool: A systematic literature revision. *Sustainability*, 13(19), Article 10698. <https://doi.org/10.3390/su131910698>

12. Rzemieniak, M., & Wawer, M. (2021). Employer branding in the context of the company's sustainable development strategy from the perspective of gender diversity of Generation Z. *Sustainability*, 13(2), Article 828. <https://doi.org/10.3390/su13020828>
13. Santos, S., Augusto, L., Ferreira, S., Espírito Santo, P., & Vasconcelos, M. (2023). Recommendations for internal communication to strengthen the employer brand: A systematic literature review. *Administrative Sciences*, 13(10), Article 223. <https://doi.org/10.3390/admsci13100223>
14. Thang, N. N., & Trang, P. T. (2024). Employer branding, organization's image and reputation, and intention to apply: The moderating role of the availability of organizational information on social media. *Frontiers in Sociology*, 9, Article 1256733. <https://doi.org/10.3389/fsoc.2024.1256733>
15. Thao, H. T., Kim, L. H., & Kim, Y.-J. (2024). Employer branding: How current employee attitudes attract top talent and new customers. *Administrative Sciences*, 14(12), Article 342. <https://doi.org/10.3390/admsci14120342>

TROVANJE PODATAKA U ETL PROCESIMA POSLOVNE INTELIGENCIJE

MAJA CERJAN

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

KORNELIJE RABUZIN

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

DUNJA VIŠNJIĆ

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

SAŽETAK

Poslovno odlučivanje u suvremenim organizacijama u sve većoj mjeri ovisi o sustavima poslovne inteligencije, a njihov temelj čine ETL procesi, koji prikupljaju podatke iz različitih izvora, te ih nakon toga obrađuju i pohranjuju u skladišta podataka. Usporedno s time jača i prijetnja trovanja podataka, pri kojem se u skupove podataka namjerno unose iskrivljeni ili lažni zapisi. Iako se ta prijetnja dosad istraživala gotovo isključivo na razini modela strojnog učenja, ETL procesi kao infrastruktura poslovne inteligencije ostali su izvan istraživačkog interesa. Ovaj rad, temeljen na strukturiranom pregledu preko 30 različitih stručnih literatura, povezuje trovanje podataka s ETL procesima i ranjivost razmatra zasebno za sve tri faze, ekstrakciju, transformaciju i punjenje, uz razgraničenje trovanja od uobičajenih problema kvalitete podataka. Analiza pokazuje da svaka faza ima vlastite oblike izloženosti te da ni transformacija, premda zamišljena kao postupak čišćenja, ne jamči pouzdanu zaštitu. Uočene ranjivosti, scenariji napada, posljedice, načini otkrivanja i protumjere objedinjeni su u sintetskom prikazu, uz poseban osvrt na marketinšku analitiku, gdje otrovani podaci neposredno narušavaju segmentaciju kupaca i raspodjelu proračuna kampanja. Predlažu se zaštitne mjere poput provjere podrijetla izvora, naprednije detekcije anomalija, praćenje podrijetla podataka te njihovo povezivanje u višeslojnu obranu. Budući da je rad konceptualan, kao takav otvara smjer za buduća eksperimentalna istraživanja.

KLJUČNE RIJEČI: trovanje podataka, ETL procesi, poslovna inteligencija, skladište podataka, sigurnost podataka, integritet podataka, praćenje podrijetla podataka, marketinška analitika

1. UVOD

Odluke koje organizacije danas donose sve više se izvode iz podataka obrađenih u složenim sustavima poslovne inteligencije. Okosnicu tih sustava čine ETL procesi, dakle ekstrakcija, transformacija i punjenje, koji podatke iz različitih izvora spajaju, pročišćavaju i pripremaju za analizu u skladištu podataka (Kimball i Caserta, 2004). Pouzdanost takvih odluka izravno ovisi o pouzdanosti procesa kroz koje su podaci prošli.

Kako strojno učenje i umjetna inteligencija sve dublje ulaze u poslovne sustave, među sigurnosnim stručnjacima raste pozornost prema jednom posebnom obliku napada, trovanju podataka. Pod tim se pojmom podrazumijeva namjerno unošenje iskrivljenih ili lažnih zapisa u skupove podataka na koje se oslanjaju algoritmi i analitički sustavi (Barreno i dr., 2006).

Da pažljivo konstruirani otrovani zapisi u skupu za treniranje mogu osjetno podići pogrešku klasifikatora, formalno su dokazali Biggio i dr. (2012). Novija mjerenja idu i dalje, izmjena tek 3% podataka za treniranje dovoljna je da pogreška modela naraste s 3% na čak 24% (Koh i dr., 2022). U zdravstvu je pak trovanje samo 0,001% medicinskih zapisa povećalo učestalost štetnih preporuka za gotovo 5% (Alber i dr., 2025).

Iz perspektive strojnog učenja tema je razmjerno dobro pokrivena. Dostupni su opsežni pregledi vrsta napada i algoritama (Cinà i dr., 2023; Goldblum i dr., 2022; Tian i dr., 2022; Zhao i dr., 2025), a taksonomiju je u međuvremenu preuzela i standardizacijska praksa (Vassilev i dr., 2025). Takvi se radovi bave učincima na modele, a kad uopće razmatraju put kojim podaci pristižu, zadržavaju se na cjevovodu strojnog učenja, dok ETL procesi, koji povezuju izvorne sustave sa skladištem, ostaju po strani. Premda svaka ETL faza napadaču nudi drukčiji manevarski prostor, sustavna analiza njihove ranjivosti na trovanje dosad nije napravljena.

Upravo tu prazninu ovaj rad nastoji popuniti. Pitanje od kojeg se polazi zapravo je jednostavno, iako odgovor nije. Što se dogodi kad se ono što o trovanju znamo iz istraživanja strojnog učenja primijeni na ETL, dakle na infrastrukturu kroz koju podaci prolaze prije nego što ih itko uopće analizira. Da bi se na to moglo odgovoriti, podijeljeno je na četiri manja pitanja.

- IP1. Na kojim je točkama ETL proces izložen trovanju i po čemu se ta izloženost razlikuje između ekstrakcije, transformacije i punjenja?
- IP2. Po čemu se trovanje razlikuje od uobičajenih problema kvalitete podataka i zašto ga standardni mehanizmi čišćenja ne prepoznaju?
- IP3. Koje protumjere proizlaze iz postojeće literature i kako ih povezati u obranu koja pokriva cijeli tok podataka?
- IP4. Kako se otrovani podaci prelijevaju u marketinšku analitiku i kakve odluke pritom izobličuju?

Ciljevi rada izravno proizlaze iz postavljenih pitanja, pa ih nije potrebno posebno nabrajati. Dovoljno je reći da se rad želi smjestiti između dviju literatura koje se, barem koliko je poznato, dosad nisu srele, one o trovanju podataka i one o ETL procesima i skladištenju. Od rada se očekuju tri stvari. Prvo, da razgraniči trovanje od običnih problema kvalitete podataka, jer se u praksi ta dva pojma miješaju gotovo redovito. Drugo, tablicu koju netko tko vodi skladište podataka može uzeti i proći kroz nju kao kroz popis za provjeru. Treće, nekoliko pretpostavki dovoljno konkretnih da ih se može eksperimentalno provjeriti, što ovaj rad ne radi, ali netko drugi bi mogao.

Kome bi to trebalo koristiti? Ponajprije inženjerima ETL-a i onima koji vode skladišta podataka, jer njima nitko ne govori da su i oni sigurnosna meta. Zatim analitičarima i voditeljima marketinga, koji kad se nešto iskrivi to vide kao čudnu brojku u izvješću a ne kao sigurnosni incident. Službenicima za sigurnost informacija rad daje argument da opseg zaštite prošire s modela na podatkovnu infrastrukturu, a onima koji se bave usklađenošću vrijedi znati da sljedivost podataka za visokorizične sustave traži i europska Uredba o umjetnoj inteligenciji (Europski parlament i Vijeće Europske unije, 2024).

Nakon opisa metodologije obrađuju se pojam i taksonomija trovanja podataka te njegovo razgraničenje od problema kvalitete, potom uloga ETL procesa unutar poslovne inteligencije, a zatim se po fazama ETL-a analiziraju konkretni vektori napada, sažeti u sintetskom prikazu ranjivosti i protumjera. Marketinškoj se analitici daje poseban naglasak jer se odluke o segmentaciji, ciljanju i personalizaciji izvode neposredno iz podataka koji su prošli ETL.

2. METODOLOGIJA

Potrebno je uvodno naglasiti da je rad konceptualne naravi. Ranjivosti o kojima se piše nisu izmjerene nego izvedene iz literature, pa je metoda u osnovi strukturirani pregled literature, pri čemu je pojam strukturiranog pregleda u ovom radu primijenjen u užem smislu. Nije riječ o sustavnom pregledu s protokolom, nego o pregledu s unaprijed određenim bazama, ključnim riječima i kriterijima, koje se navode u Tablici 1.

Razlog zašto se nije moglo krenuti od postojećeg korpusa radova o trovanju u ETL-u jednostavan je, takvog korpusa nema. Nađeni su radovi o trovanju modela, radovi o sigurnosti skladišta i radovi o kvaliteti podataka, ali nijedan koji bi te tri stvari spojio. Okvir je zato izveden tako da je iz radova o trovanju izdvojen mehanizam napada (što napadač radi, kakav pristup mu treba i koliki udio otrovanih zapisa da bi nešto postigao) te obranu ako je predložena i njezine granice, a onda se za svaki mehanizam pitao u kojoj bi fazi ETL-a mogao djelovati. Podjela na faze preuzeta je od Kimballa i Caserte (2004) i Vassiliadis (2009).

Samo pretraživanje išlo je u tri koraka, najprije baze, zatim čitanje naslova i sažetaka pa cijelih radova, i na kraju praćenje referenci u oba smjera, dakle što odabrani radovi citiraju i tko citira njih.

Tablica 1. Postupak pregleda literature

Element	Opis
Baze i izvori	Web of Science, Scopus, IEEE Xplore, ACM Digital Library, ScienceDirect, SpringerLink, arXiv, Google Scholar; za smjernice i propise NIST, OWASP, EUR-Lex
Ključne riječi	data poisoning, poisoning attack, adversarial machine learning, clean-label attack, backdoor attack, ETL process, ETL security, data warehouse security, data quality, data validation, data lineage, data provenance, marketing analytics, review fraud (kombinacije s AND i OR)
Razdoblje	1996.–2026., težište 2018.–2025.
Jezik	engleski, hrvatski
Uključeno	recenzirani i pregledni radovi, referentne knjige o skladištenju, službene smjernice i propisi; rad mora opisivati mehanizam napada ili obrane, arhitekturu ETL-a ili kvalitetu i sljedivost podataka

Element	Opis
Isključeno	napadi u fazi zaključivanja, radovi bez opisa mehanizma, ponovljene inačice istog rada, neregizirani izvori (osim smjernica i propisa), radovi nedostupni u cijelosti
Uključeno jedinica	31: 18 izvornih radova, 8 preglednih, 2 knjige, 3 smjernice i propisi

Izvor: Autori

Ograničenja su očita i ne smiju se prešutjeti. Odabir radova podložan je subjektivnoj procjeni autora, s obzirom na to da nije provedena nezavisna provjera od strane drugog ocjenjivača. Radovi koji se bave isključivo algoritamskom stranom napada svjesno su izostavljeni, premda su za samo strojno učenje važni, jer se iz njih ne da izvući ništa što bi se moglo preslikati na ETL. I na kraju, cijeli okvir počiva na prijenosu iz jednog konteksta u drugi, a prijenos je pretpostavka, ne nalaz.

3. PREGLED LITERATURE

Sigurnost sustava strojnog učenja postaje predmetom ozbiljnijeg istraživanja sredinom 2000-ih. Dalvi i dr. (2004) među prvima upozoravaju da se klasifikacijski sustav može kompromitirati ako napadač razumije logiku njegova rada. Dvije godine kasnije Barreno i dr. (2006) otvaraju pitanje može li strojno učenje uopće biti sigurno i predlažu taksonomiju koja uzročne napade, usmjerene na podatke za treniranje, razdvaja od istraživačkih, koji se odvijaju u fazi testiranja. Taj se rad uobičajeno uzima kao ishodište istraživanja protivničkog strojnog učenja.

Sam pojam napada trovanjem podataka (engl. poisoning attack) u literaturu uvode Biggio i dr. (2012), pokazavši kako ubacivanje posebno oblikovanih zapisa u skup za treniranje znatno podiže pogrešku klasifikatora temeljenog na potpornim vektorima (SVM). Jagielski i dr. (2018) isti problem nekoliko godina poslije prenose na regresiju, što za poslovnu analitiku nije nevažno s obzirom da se predviđanja prodaje i procjene vrijednosti kupca grade upravo na regresijskim modelima. Shafahi i dr. (2018) potom otkrivaju da napadač uopće ne mora upravljati oznakama, točnije rečeno njihov napad s čistim oznakama (engl. clean-label attack) mijenja ponašanje modela ubacivanjem primjera koji djeluju posve ispravno.

Posljednjih je godina objavljeno više preglednih radova koji temu obrađuju sustavno. Biggio i Roli (2018) sažimaju prvo desetljeće istraživanja protivničkog strojnog učenja. Goldblum i dr. (2022) razvrstavaju ranjivosti skupova podataka, među njima trovanje i ugrađivanje stražnjih vrata u modele. Tian i dr. (2022) i Cinà i dr. (2023) donose opsežne sistematizacije napada trovanjem, a Zhao i dr. (2025) analizu šire na duboko učenje i velike jezične modele. Hartle i dr. (2025) sustavno pregledavaju radove iz razdoblja od 2018. do 2025. i upozoravaju da već neznatni zahvati u podatke za treniranje mogu izazvati ozbiljne posljedice u područjima kao što su zdravstvo i financije. Da je područje sazrelo vidi se i po tome što je taksonomiju u međuvremenu preuzeo NIST (Vassilev i dr., 2025), a OWASP (2025) prijetnju izrijekom širi i na sustave velikih podataka koji uopće ne koriste modele umjetne inteligencije.

Literatura o sigurnosti samih ETL procesa pritom je osjetno tanja. Kimball i Caserta (2004) te Inmon (2005) detaljno opisuju arhitekturu i faze, no sigurnosni aspekt ostavljaju po strani. Vassiliadis (2009) u svom pregledu ETL tehnologije probleme doduše razvrstava po fazama, što je poslužilo za podjelu, ali ih gleda kroz modeliranje, optimizaciju i kvalitetu, napadača u tom pregledu nema. Ono što o sigurnosti ETL-a i skladišta ipak postoji bavi se gotovo isključivo

time tko podatke smije vidjeti. Gosain i Arora (2015) nabrajaju kontrolu pristupa, autentikaciju, šifriranje, kontrolu zaključivanja i reviziju, a Dammak i dr. (2019), koji su predložili meta-model sigurnosnih zahtjeva baš za ETL, polaze također od povjerljivosti. Integritet se spominje, ali u smislu da netko neovlašteno mijenja postojeće zapise. Slučaj koji je zanimljiv, da netko posve ovlašteno unosi zapise koji su lažni od početka, u toj literaturi se ne pronalazi, a razlika nije sitna jer napadač koji podmeće izmišljene recenzije ne krši nijednu kontrolu pristupa, on sučelje koristi točno onako kako je i zamišljeno.

Treći niz radova, onaj o kvaliteti podataka, problemu je bliži nego što bi se reklo. Wang i Strong (1996) davno su postavili okvir u kojem točnost nije jedina dimenzija kvalitete, uz nju stoje vjerodostojnost, potpunost, ugled izvora, a upravo je vjerodostojnost ono što trovanje pogađa. Schelter i dr. (2018) te Polyzotis i dr. (2019) opisuju alate za automatsku provjeru kvalitete u velikim cjevovodima, s praćenjem razdiobi kroz vrijeme i alarmom kad nešto odstupi. Problem je što su ti alati građeni uz prešutnu pretpostavku da su pogreške slučajne. Što se događa kad netko pogreške radi namjerno i zna kako alat radi, na to Koh i dr. (2022) daju prilično neugodan odgovor, o kojem će više riječi biti u petom poglavlju. Steinhardt i dr. (2017) pokazuju da se za obrane koje najprije izbace netipične vrijednosti mogu izvesti jamstva, ali samo ako se polazi od pretpostavke kako otrovani zapisi izgledaju. Cui i Widom (2003) razradili su praćenje podrijetla zapisa kroz opće transformacije u skladištu, što je za istragu trovanja gotovo idealan alat, no u literaturi se dosljedno tretira kao pomoć pri ispravljanju grešaka i osvježavanju pogleda, nikad kao sigurnosni mehanizam. Spoczynski i dr. (2025) tu ideju vraćaju u sigurnosni kontekst, ali za cjevovod strojnog učenja, ne za ETL.

Sintezom navedenog, može se uočiti nedostatak komunikacije i razmjene spoznaja između triju spomenutih istraživačkih zajednica. Oni koji istražuju protivničko strojno učenje mehanizme napada opisuju vrlo precizno, ali podatke uzimaju kao zadan skup i rijetko se pitaju odakle je došao. Oni koji se bave skladištenjem infrastrukturu poznaju do zadnjeg detalja, a napadač im se u modelima uopće ne pojavljuje. Oni koji se bave kvalitetom imaju mjerne instrumente koji bi trovanje vjerojatno mogli uhvatiti, samo što su ih gradili za nešto drugo. Ima i iznimaka. Carlini i dr. (2024) opisali su napade koji iskorištavaju samu mehaniku prikupljanja s weba, kupnju isteklih domena s kojih se podaci povlače i podmetanje izmjena neposredno prije zakazanog prikupljanja, i izračunali da su za šezdesetak dolara mogli otrovati 0,01% nekih od najvećih javnih skupova podataka. To više nije teorija. Zhao i dr. (2025) pak razlikuju prikupljanje, obradu i treniranje te upozoravaju da se zaraženi zapisi mogu podmetnuti već pri prikupljanju, a da ih se odmah ne primijeti. Oba rada, međutim, ostaju kod cjevovoda strojnog učenja.

Ovaj se rad od navedenog razlikuje po tome što mu jedinica analize nije model ni skup podataka, nego faza ETL procesa. Mehanizmi i brojke preuzeti su iz te literature, u tome nema ničeg novog. Novo je, ako je uopće novo, to što su smješteni u infrastrukturu koja hrani izvješća, nadzorne ploče i marketinške sustave, dakle u sloj gdje model strojnog učenja često uopće ne postoji, a posljedice pogrešnih podataka postoje itekako.

4. TROVANJE PODATAKA I KVALITETA PODATAKA

4.1. POJAM I KLASIFIKACIJA

Trovanje podataka napad je u kojem protivnik u skup podataka, namijenjen treniranju modela ili donošenju odluka, svjesno unosi lažne, iskrivljene ili zlonamjerno oblikovane zapise.

Za razliku od napada koji pogađaju model u radu, trovanje se odvija već pri pripremi podataka, što znači da ga je teže otkriti jer se zlonamjerni zapisi stope s ispravnima prije nego sustav uopće proradi (Biggio i dr., 2012).

Barreno i dr. (2006, 2010) postavili su temeljnu razdiobu napada na tri osi: uzročni naspram istraživačkih, ciljani naspram neciljanih te oni usmjereni na integritet naspram onih usmjerenih na dostupnost sustava. Trovanje podataka ulazi među uzročne napade jer pogađa upravo podatke iz kojih model uči. Tu su klasifikaciju kasniji radovi dodatno razradili. Biggio i dr. (2012) prikazali su neciljani napad na klasifikator s potpornim vektorima, u kojem ubačeni zapisi pomiču granicu odlučivanja i podižu ukupnu pogrešku. Shafahi i dr. (2018), uvode ciljani napad s čistim oznakama gdje napadač ne dira oznake, nego oblikuje sadržaj primjera tako da utječe na razvrstavanje jednog određenog uzorka. Opasnost je tim veća što takvi zapisi i vizualno i statistički djeluju posve ispravno. Zasebnu skupinu čine napadi ugrađivanjem stražnjih vrata (engl. backdoor attacks), kod kojih napadač u podatke za treniranje ubacuje okidač koji željeno ponašanje modela pokreće tek kad se taj okidač pojavi u ulazu (Goldblum i dr., 2022).

Razmjere moguće štete dokumentira više istraživanja. Cotroneo i dr. (2024) utvrđuju da generatori programskog koda postaju ranjivi već pri manje od 3% otrovanih podataka, a pri udjelu od oko 6% uspješnost napada raste u svim ispitanim modelima. Navedeni primjeri, zajedno s onima iz uvoda, pokazuju da za ozbiljne posljedice nije potrebna velika količina zlonamjernih zapisa, zbog čega je trovanje osobito opasno za sustave koji, poput ETL procesa, obrađuju podatke iz više neprovjerenih izvora.

4.2. RAZGRANIČENJE OD PROBLEMA KVALITETE PODATAKA

U praksi se trovanje vrlo lako pomiješa s običnim problemima kvalitete podataka, i to s razlogom, jer na kraju oboje izgleda isto: u tablici stoji zapis koji ne odgovara stvarnosti. Razlika nije u tome kako zapis izgleda, nego kako je nastao i, što je za obranu bitnije, kako se ponaša kad ga se pokuša uhvatiti.

Loša kvaliteta nastaje nenamjerno. Wang i Strong (1996) njezine izvore vide u pogreškama pri unosu, neusklađenim definicijama među sustavima, zastarjelim ili nepotpunim zapisima. Takve su pogreške u pravilu slučajne, često se grupiraju oko jednog izvora ili jednog razdoblja (svatko tko je radio s ETL-om zna za onaj jedan sustav koji šalje datume u krivom formatu) i, što je ključno, iza njih ne stoji nikakva namjera. Uvede li se provjera raspona, pogreške izvan raspona nestaju i više se ne vraćaju. Kod trovanja je obrnuto. Napadač kontrole poznaje ili ih barem pretpostavlja, pa zapise oblikuje tako da kroz njih prođu, a Koh i dr. (2022) pokazali su da to vrijedi i za naprednije metode detekcije anomalija, ne samo za provjere raspona. Kontrola koja je slučajne pogreške uspješno uklonila ovdje ne pomaže, štoviše, njezino uvođenje napad samo preusmjeri na drugo mjesto. Razlikuje se i statistički otisak, slučajne pogreške obično odskaču od razdiobe pa ih detektori vide, dok otrovani zapisi mogu biti nerazlučivi od legitimnih. Razlikuje se raspodjela u vremenu, jer slučajne pogreške prate kvarove i promjene u izvornim sustavima, a napadač trenutak bira sam i, ako je pametan, zapise raspoređuje kroz više ciklusa punjenja. I na kraju opseg: da bi slučajne pogreške pokvarile agregat mora ih biti mnogo, jer se u agregatu djelomično poništavaju, dok kod trovanja literatura govori o udjelima od 0,001% do nekoliko postotaka (Alber i dr., 2025; Koh i dr., 2022).

Iz toga slijedi zaključak koji se u literaturi o kvaliteti podataka, prema dostupnim saznanjima, rijetko izriče otvoreno: od mjera osmišljenih za kvalitetu ne treba očekivati zaštitu od trovanja.

One i dalje vrijede kao prvi filter i nitko ih ne bi trebao ukidati, ali protiv protivnika koji ih poznaje nisu obrana.

5. RANJIVOST ETL PROCESA NA TROVANJE PODATAKA

5.1. ULOGA ETL PROCESA U POSLOVNOJ INTELIGENCIJI

ETL procesi povezuju operativne izvorne sustave sa skladištem podataka i odvijaju se u tri faze: ekstrakciji, transformaciji i punjenju. Njihova zadaća nije isključivo tehnička, oni odlučuju koji će podaci, u kojem obliku i koje kvalitete ući u skladište podataka, a iz njega se potom izvode sve analize i izvješća (Kimball i Caserta, 2004). Inmon (2005) skladište opisuje kao predmetno orijentirano, integrirano, vremenski varijantno i nepromjenjivo, a integraciju podataka iz nepovezanih izvora drži jednim od najtežih temeljnih zadataka, koji se ostvaruje upravo kroz ETL.

Uz takvu ulogu dolazi i poseban status povjerenja. U praksi se skladište tretira kao jedinstven i pouzdan izvor istine za cijelu organizaciju, pa čim podaci prođu ETL i nađu se u njemu, analitičari i sustavi koji ih koriste pretpostavljaju da su točni i potpuni. Kvaliteta se, međutim, ne stvara u skladištu, nego ranije, tijekom ETL-a, gdje se podaci čiste, validiraju i usklađuju. ETL je zato kontrolna točka integriteta podataka u cijelom sustavu.

Ta ga uloga istodobno čini najosjetljivijom karikom poslovne inteligencije. Kako svi podaci prolaze istim uskim grlom, a kasnije se odluke oslanjaju na pretpostavku njihove ispravnosti, bilo kakva kompromitacija unutar ETL-a širi se na cijeli analitički sloj, od izvješća do modela strojnog učenja. Sigurnosna se strana ETL-a rijetko razmatra, pa je on u isti mah dragocjena i slabo branjena meta. Kako se ta ranjivost očituje u svakoj od triju faza, pokazuju potpoglavlja koja slijede.

5.2. FAZA EKSTRAKCIJE

Ekstrakcija označava prikupljanje podataka iz izvornih sustava. Prema Kimballu i Caserti (2004), to mogu biti relacijske baze, datoteke različitih formata, XML izvori, web zapisnici, ERP sustavi i drugi heterogeni izvori. Što je izvora više, to je i više mjesta na kojima napadač može djelovati.

Goldblum i dr. (2022) upozoravaju da automatsko prikupljanje bez ljudskog nadzora izlaže organizaciju riziku, jer izostanak kontrole nad tim korakom ostavlja prostor za manipulaciju. Shafahi i dr. (2018) opisuju i konkretan scenarij gdje napadač otrovane podatke jednostavno objavi na internetu i pričekava da ih automatizirani sustav sam preuzme. Za ETL to znači da svaki vanjski izvor iz kojega se ekstrahira može postati ulazna točka za otrovane podatke. Carlini i dr. (2024) tome dodaju nešto o čemu se u ETL krugovima, uopće ne razmišlja: sadržaj na nekoj adresi može se promijeniti između trenutka kad je izvor odobren i trenutka kad ga ETL stvarno povuče. U praksi se izvor najčešće odobrava samo jednom, prilikom inicijalnog uključivanja, nakon čega izostaje naknadna provjera, iako se podaci iz njega kontinuirano preuzimaju godinama.

Trebaju se uzeti u obzir i mehanizmi za otkrivanje promjena u izvornim sustavima, koje Kimball i Caserta (2004) ubrajaju u ključne dijelove ekstrakcije. Napadač s pristupom izvoru

može podmetnuti zapise nalik legitimnim promjenama, a ETL će ih u idućem ciklusu preuzeti bez ikakve dodatne provjere.

Kao primjer neka posluži tvrtka koja bazu kupaca obogaćuje podacima o proizvodima i recenzijama prikupljenima s vanjskih web izvora. Otvori li napadač mnoštvo lažnih korisničkih računa i upiše izmišljene recenzije ili ocjene, izravno utječe na ono što ETL redovito preuzima. Kako takvi zapisi dolaze s naizgled legitimnog izvora i formatom ne odskaku, prolaze bez dodatne provjere te poslije iskrivljuju analize zadovoljstva kupaca i preporuke proizvoda.

5.3. FAZA TRANSFORMACIJE

Transformacija obuhvaća čišćenje, validaciju i usklađivanje, pa bi na prvi pogled trebala djelovati kao obrana sustava, neispravne bi zapise trebalo prepoznati i ukloniti već pri čišćenju. Zbog toga su napadi na ovu fazu i usmjereni na oblikovanje zapisa koji kroz standardne provjere prolaze a da ne podignu nikakvu uzbunu.

Koh i dr. (2022) pokazuju da se trovanje može oblikovati tako da izmakne uobičajenoj obrani zasnovanoj na detekciji anomalija, uključujući metode najbližih susjeda, gubitka pri treniranju i dekompozicije singularnih vrijednosti. Iz njihovih rezultata slijedi da otrovani zapisi statistički mogu biti nerazlučivi od legitimnih, a da pritom osjetno mijenjaju ponašanje sustava. Za transformaciju to znači da zapise koji zadovolje provjere raspona, formata i konzistentnosti standardna pravila čišćenja neće prepoznati kao prijetnju. Ni formalna jamstva u ovom slučaju ne pružaju željenu razinu zaštite, jer ona koja su izveli Steinhardt i dr. (2017) vrijede samo dok otrovani zapisi izgledaju onako kako je pretpostavljeno, a napadač koji tu pretpostavku prekrši jednostavno ispada iz njihova dosega.

Transformacija često uključuje i objedinjavanje podataka iz više izvora. Kimball i Caserta (2004) usklađivanje opisuju kao razrješavanje nesuglasja među izvorima, kako bi se podaci u skladištu mogli koristiti zajedno. Pri tom se spajanju otrovani zapisi iz jednog izvora spoje u legitimne podatke iz drugih, što njihovo naknadno otkrivanje dodatno otežava. Što je transformacija zamršenija, teže je slijediti podrijetlo pojedinog podatka i utvrditi je li negdje usput bio kompromitiran. Pri spajanju transakcija iz više prodajnih kanala napadač, primjerice, može ubaciti izmišljene transakcije s iznosima i datumima unutar očekivanih raspona, koje prolaze sve provjere jer se ni po čemu ne razlikuju od pravih, a nakon agregacije umjetno napuhuju vrijednost pojedinih kupaca ili skupina proizvoda.

5.4. FAZA PUNJENJA

U punjenju se transformirani podaci predaju skladištu, odakle hrane analitiku, izvješćivanje i odlučivanje. Čim otrovani zapisi uđu u skladište, stječu status provjerenih i pouzdanih podataka, pa nijedan korisnik poslije nema razloga posumnjati u njihovu ispravnost. Kimball i Caserta (2004) upravljanje dimenzijskim tablicama, zajedno s obradom sporo mijenjajućih dimenzija, ubrajaju u ključne dijelove punjenja. Ti mehanizmi prate promjene atributa tijekom vremena. Uspije li napadač u dimenzijsku tablicu podmetnuti lažnu promjenu, može poremetiti ne samo buduće analize nego i povijesne prikaze, ovisno o tome koji se tip sporo mijenjajuće dimenzije koristi.

Osobit rizik kriju inkrementalni ciklusi punjenja. Kako se skladišta redovito osvježavaju novim podacima, napadač otrovane zapise ne mora ubaciti odjednom i u velikoj količini. Može ih, naprotiv, kroz niz ciklusa unositi u malim količinama koje pojedinačno ne pobuđuju sumnju, a

zbroje li se, iskrivljuju analitičke rezultate. Hartle i dr. (2025) napominju da i posve sitne manipulacije znaju izazvati znatne poremećaje, zbog čega je upravo takve postupne napade najteže uočiti.

Kao primjer može se uzeti dimenzija kupca u kojoj se bilježi pripadnost tržišnom segmentu. Podmetne li napadač lažnu promjenu segmenta, prihod se može preusmjeriti u pogrešan segment, i to u budućim, a ovisno o načinu vođenja sporo mijenjajuće dimenzije i u povijesnim izvješćima. Suptilnija je inačica dodavanje tek nekoliko izmišljenih prodajnih zapisa u svakom ciklusu, gdje je svaki za sebe neprimjetan, no kroz dulje razdoblje zajedno iskrivljuju trend prodaje na kojem se grade predviđanja i proračunske odluke. Gdje nema praćenja podrijetla podataka (Cui i Widom, 2003; Spoczynski i dr., 2025), a u mnogim ETL sustavima ono još nije uobičajeno, otrovani podaci jednom uneseni u skladište mogu dugo ostati neprimijećeni.

5.5. SINTETSKI PRIKAZ RANJIVOSTI I PROTUMJERA

Tablica 2 sve navedeno slaže u jedan pregled, gdje za svaku ranjivost stoji scenarij napada, posljedica, način na koji bi se moglo otkriti i protumjera. Oznake E, T i P upućuju na fazu. Tablični prikaz sažima ključne informacije detaljnije razrađene u tekstu te je strukturiran kao kontrolni popis za praktičnu provjeru sigurnosti ETL sustava.

Tablica 2. Ranjivosti, scenariji, posljedice, otkrivanje i protumjere po fazama ETL procesa

Ranjivost	Scenarij napada	Posljedica	Otkrivanje	Protumjera
EKSTRAKCIJA				
E1. Nekontrolirano preuzimanje s vanjskih izvora	Lažni računi, izmišljene recenzije i ocjene	Iskrivljene analize zadovoljstva kupaca	Broj novih zapisa i identiteta po izvoru	Popis odobrenih izvora, autentikacija sučelja
E2. Otkrivanje promjena u izvoru bez provjere	Podmetnute promjene nalik legitimima	Ulaze kao redovito osvježanje	Broj promjena po ciklusu naspram povijesti	Kontrolne sume paketa, odvojena prava pisanja i replikacije
E3. Sadržaj izvora mijenja se nakon odobrenja	Istekla domena, izmjena prije preuzimanja (Carlini i dr., 2024)	Preuzet sadržaj koji nitko nije odobrio	Sažeci datoteka između ciklusa	Zamrznuta snimka izvora, povremena ponovna provjera
TRANSFORMACIJA				
T1. Pravila čišćenja ne vide namjeru	Zapisi unutar očekivanih raspona	Otrovano dobiva status očišćenog	Praćenje razdiobi kroz cikluse	Profiliranje, praćenje pomaka (Polyzotis i dr., 2019; Schelter i dr., 2018)
T2. Detekcija anomalija koju se da zaobići	Napad prilagođen detektoru (Koh i dr., 2022)	Lažan osjećaj sigurnosti	Više neovisnih detektora	Slojevita detekcija, svijest o granicama (Steinhardt i dr., 2017)
T3. Objedinjavanje briše podrijetlo	Izmišljene transakcije iz jednog kanala	Napuhana vrijednost kupaca, križa segmentacija	Agregati po izvoru prije i poslije spajanja	Oznaka izvora zadržana kroz transformaciju
PUNJENJE				

Ranjivost	Scenarij napada	Posljedica	Otkrivanje	Protumjera
P1. Ulazak u skladište daje status pouzdanog	Otrovani zapisi postaju izvor istine	Nitko više ne sumnja	Revizija skladišta, uzorkovanje po izvoru	Revizijski atributi u staging sloju
P2. Sporo mijenjajuće dimenzije	Lažna promjena segmenta kupca	Prihod u krivom segmentu, i unatrag	Učestalost promjena po atributu	Odobranje osjetljivih promjena
P3. Inkrementalno punjenje	Po nekoliko zapisa u svakom ciklusu	Iskrivljen trend, kriva predviđanja	Kumulativna odstupanja od trenda	Pragovi za kumulativna odstupanja, praćenje podrijetla (Cui i Widom, 2003; Spoczynski i dr., 2025)

Izvor: Autori na temelju pregledane literature

6. MJERE ZAŠTITE ETL PROCESA OD TROVANJA PODATAKA

Iz analize slijedi da se zaštita ETL-a od trovanja ne smije svesti na jednu mjeru ni na jednu fazu, nego traži nekoliko usklađenih smjerova koji zajedno pokrivaju cijeli put podataka, od izvora do skladišta. Prvi i osnovni smjer odnosi se na provjeru podrijetla i vjerodostojnosti izvora, jer je nekontrolirano preuzimanje s neprovjerenih mjesta najlakši ulaz za otrovane zapise. U praksi to znači ekstrakciju ograničiti na popis odobrenih izvora s jasno određenom odgovornom osobom, pristup vanjskim sustavima i sučeljima autenticirati te integritet preuzetih datoteka provjeriti kontrolnim sumama prije daljnje obrade. Time se izravno odgovara na upozorenje Goldbluma i dr. (2022) da automatizirano prikupljanje bez nadzora otvara prostor manipulaciji, kao i na nalaz Shafahija i dr. (2018) da napadač otrovane podatke najlakše plasira preko javno dostupnih kanala. Nakon Carlinija i dr. (2024) odobreni izvori se povremeno provjere iznova, ne samo kad ih se uključuje.

Drugi smjer jača detekciju u fazi transformacije, gdje se pokazalo da standardna pravila čišćenja pomno oblikovane otrovane zapise ne prepoznaju pouzdano. Kako Koh i dr. (2022) dokazuju da se napad može složiti tako da zaobiđe uobičajene metode otkrivanja anomalija, preporučljivo je uvesti statističko praćenje koje distribuciju podataka motri tijekom vremena i javlja postupne pomake koji bi mogli upućivati na trovanje. Kroz uzastopne cikluse tako se prate veličine poput broja zapisa po izvoru, udjela praznih ili prvi put viđenih vrijednosti i razdiobe ključnih mjera, primjerice iznosa transakcija ili ocjena proizvoda, a svako iskakanje iz povijesnih raspona postaje povod za ručnu provjeru prije punjenja skladišta. Prednost je u tome što te alate nije potrebno razvijati od početka, alati koje opisuju Schelter i dr. (2018) i Polyzotis i dr. (2019) rade upravo to, samo ih treba namjestiti da traže i namjerne, a ne samo slučajne pogreške. Sustavnu kontrolu kvalitete podataka kao obranu od trovanja među temeljne mjere ubraja i OWASP (2025).

Treći smjer prati podrijetlo podataka kroz cijeli ETL, pa se u slučaju sumnje može rekonstruirati put svakog zapisa i odrediti mjesto na kojem je došlo do kompromitacije. Spoczynski i dr. (2025) u tu svrhu predlažu okvir koji bilježi cjelokupan životni ciklus podataka i na svakom koraku obrade omogućuje provjeru autentičnosti i integriteta. Slično se u praksi postiže revizijskim atributima u privremenom (engl. staging) sloju, kao što su podatak o izvoru zapisa,

vrijeme učitavanja i identifikator ETL posla koji ga je obradio. Vodeći alati, među njima Talend, Informatica i SQL Server Integration Services, već nude praćenje podrijetla podataka (engl. data lineage), no ta se mogućnost obično rabi za dokumentaciju i ispravljanje pogrešaka, a tek rijetko u sigurnosne svrhe. Na isto upućuje i europska Uredba o umjetnoj inteligenciji (Europski parlament i Vijeće Europske unije, 2024), koja sljedivost i dokumentiranje obrade podataka navodi među ključnim obvezama za visokorizične sustave, čime se tehničke preporuke i regulatorni okvir poklapaju.

Punu vrijednost nabrojene mjere pokazuju tek udružene u višeslojnu obranu, jer svaka zasebno donosi tek ograničen učinak, na to upozoravaju i Hartle i dr. (2025), zaključujući da djelotvorna zaštita traži otporan i višeslojan pristup. Zaštita ETL-a zato se ne bi smjela vezati uz jednu fazu, nego provjeru izvora, detekciju anomalija i praćenje podrijetla podataka treba povezati s redovitom revizijom sadržaja skladišta.

7. RASPRAVA

7.1. DOPRINOS RADA

U ovom radu nije razvijen nijedan novi mehanizam napada ni obrane i nije izmjerena izloženost nijednog stvarnog sustava. Ono što rad radi jest da mijenja jedinicu analize, jer radovi o trovanju gledaju model ili skup za treniranje, a ovdje se gleda faza ETL procesa gdje takvo preslikavanje u literaturi koja je pregledana nije pronađeno, iako su sami mehanizmi detaljno opisani više puta. Drugi dio doprinosa je Tablica 3, koja te mehanizme slaže u oblik koji netko može stvarno upotrijebiti, kao popis za provjeru. Postojeći pregledi (Cinà i dr., 2023; Tian i dr., 2022) napade sistematiziraju prema svojstvima algoritma, što je korisno u istraživačke svrhe, no pruža ograničenu praktičnu vrijednost inženjerima i voditeljima skladišta podataka. Treći doprinos je razgraničenje od kvalitete podataka opisano u četvrtom poglavlju, koje se može činiti kao terminološka nijansa, no ima važnu praktičku posljedicu, mjere osmišljene za slučajne greške ne mogu se prodavati kao zaštita od napada. I četvrto, prijenos na marketinšku analitiku, koju literatura o trovanju gotovo ne spominje, premda se hrani iz upravo onih izvora koje Shafahi i dr. (2018) i Carlini i dr. (2024) opisuju kao najlakše za podmetanje.

7.2. POSLJEDICE ZA MARKETINŠKU ANALITIKU

Posljedice trovanja podataka u ETL procesima najjasnije se vide u marketinškoj analitici, gdje se odluke o segmentaciji, ciljanju i personalizaciji izvode neposredno iz podataka pohranjenih u skladištu. Sustavi za upravljanje odnosima s kupcima, platforme za automatizaciju marketinga i sustavi preporuka redovito se oslanjaju na podatke koji su prošli ETL, a velik dio tih podataka stiže iz vanjskih i teško provjerljivih izvora, primjerice web obrazaca, društvenih mreža, programa vjernosti, recenzija i podataka trećih strana. Upravo su takvi javno dostupni kanali, kako pokazuju Shafahi i dr. (2018) te Goldblum i dr. (2022), najlakši put za unošenje otrovanih zapisa, pa se marketinška analitika ubraja među područja izrazito izložena toj prijetnji.

Da to nije samo teorija, pokazuje i rad koji uopće nije iz sigurnosne literature. Luca i Zervas (2016) na primjeru Yelpe utvrdili su da je otprilike 16% recenzija restorana završilo u filtru sumnjivih, da su takve recenzije ekstremnije od ostalih i da ih poduzeća češće naručuju kad im ugled padne. To su podaci koje marketinški sustavi rutinski povlače u analize zadovoljstva, a

motiv, obrazac i razmjeri manipulacije zapravo su ono što sigurnosna literatura zove trovanjem, samo pod drugim imenom.

Šteta pri tome ne nastaje zato što bi sustav prestao raditi, nego zato što se neprimjetno izobličuje slika koju organizacija ima o svojim kupcima. Lažne recenzije i ocjene kvare analize zadovoljstva, izmišljene transakcije umjetno podižu vrijednost pojedinih segmenata, a podmetnute promjene u dimenziji kupca usmjeravaju proračune kampanja prema krivim ciljnim skupinama, gdje krajnji su ishod loše raspoređen marketinški proračun, narušena personalizacija i sve slabije povjerenje u vlastitu analitiku. Budući da napadač takav učinak postiže razmjerno skromnim sredstvima, a organizacija ga zbog suptilnosti dugo ne opaža, izloženost marketinške analitike ovoj prijetnji treba shvatiti ozbiljno.

Za praksu direktnog i interaktivnog marketinga iz toga slijede dvije pouke. Prva je da kvaliteta marketinških odluka ne ovisi samo o profinjenosti analitičkih alata, nego jednako tako i o sigurnosti podatkovne infrastrukture koja te alate hrani podacima. Druga je da zaštitne mjere predložene u ovom radu, ponajprije provjera izvora, detekcija anomalija i praćenje podrijetla podataka, ne bi smjele ostati samo briga informatičkih odjela, nego trebaju postati dio upravljanja marketinškim podacima.

7.3. OGRANIČENJA I POLAZNE PRETPOSTAVKE

Rad je konceptualan po naravi, što znači da ranjivosti ETL procesa nisu utvrđene kontroliranim pokusima, nego povezivanjem poznatih mehanizama trovanja podataka s arhitekturom tih procesa. Takav postupak dopušta cjelovit pogled na problem i opis vektora napada koji dosad nisu sustavno razmotreni, ali u tome leži i glavno ograničenje, jer izloženost pojedinih faza i stvarna djelotvornost predloženih mjera nisu empirijski izmjerene. Ipak, iz analize se daju izvući tri pretpostavke koje su dovoljno određene da ih netko može provjeriti pokusom, i to se smatra prirodnim nastavkom ovoga rada.

- P1. Udio otrovanih zapisa potreban za mjerljivo izobličenje analitičkog rezultata manji je kod agregata koji ulaze u segmentaciju kupaca nego kod pokazatelja koji se računaju nad cijelom populacijom.
- P2. Zapisi podmetnuti postupno kroz niz inkrementalnih ciklusa punjenja ostaju neotkriveni dulje od jednakog broja zapisa unesenih odjednom, uz iste kontrole kvalitete.
- P3. Standardna pravila čišćenja u fazi transformacije otkrivaju znatno manji udio otrovanih zapisa nego praćenje pomaka razdiobi kroz uzastopne cikluse.

Za provjeru bi trebalo kontrolirano okruženje s poznatim ETL tokom, čist skup podataka i unaprijed određene udjele podmetnutih zapisa, pa mjeriti koliko se rezultati pomaknu i koliko od toga kontrole uhvate. Ništa od toga nije tehnički zahtjevno, samo dosad nije napravljeno.

8. ZAKLJUČAK

Trovanje podataka spada među najteže sigurnosne izazove današnjih podatkovnih sustava, no istraživanja se gotovo isključivo bave njegovim učinkom na modele strojnog učenja, a zanemaruju put kojim otrovani podaci do tih modela i analitičkih sustava uopće stižu. Rad je tu prazninu pokušao popuniti povezivanjem trovanja podataka s ETL procesima, okosnicom poslovne inteligencije.

Analiza triju ETL faza pokazala je da svaka nosi vlastite ranjivosti. Ekstrakcija je podložna manipulaciji jer se oslanja na mnoštvo, često neprovjerenih izvora. Transformacija, premda zamišljena kao čišćenje, ne uspijeva pouzdano uhvatiti napade skrojene da prođu standardne provjere. Punjenje pak dopušta postupno gomilanje otrovanih zapisa, koji nakon pohrane stječu status pouzdanih i postaju podloga odluka. Uočene ranjivosti, scenariji, posljedice, načini otkrivanja i protumjere objedinjeni su u Tablici 3, koja može poslužiti kao polazni okvir za procjenu izloženosti ETL-a u praksi. Rad ujedno razgraničuje trovanje od problema kvalitete podataka, s kojima ga se u praksi često poistovjećuje. Pregledani radovi potvrđuju i da već sitne količine otrovanih podataka izazivaju nesrazmjerno velike posljedice, što osobito pogađa marketinšku analitiku, gdje iskrivljeni podaci izravno utječu na segmentaciju, ciljanje i raspodjelu proračuna kampanja.

Kao odgovor na uočene ranjivosti predložene su četiri komplementarne mjere: provjera podrijetla izvora, naprednija detekcija u transformaciji, praćenje podrijetla podataka kroz cijeli proces te njihovo povezivanje u višeslojnu obranu. Te se mjere poklapaju i s postojećim sigurnosnim smjernicama i s regulatornim zahtjevima za sljedivost podataka. Najveće ograničenje rada njegova je konceptualnost, jer opisani scenariji nisu provjereni eksperimentom. Buduća bi istraživanja mogla početi od pretpostavki P1 do P3, razviti eksperimentalne modele i njima izmjeriti stvarnu izloženost ETL procesa pojedinim vrstama trovanja te ocijeniti koliko predložene protumjere doista vrijede u stvarnim sustavima poslovne inteligencije.

REFERENCE

1. Alber, D. A., Yang, Z., Alyakin, A., Yang, E., Rai, S., ... Oermann, E. K. (2025). Medical large language models are vulnerable to data-poisoning attacks. *Nature Medicine*, 31, 618–626. <https://doi.org/10.1038/s41591-024-03445-1>
2. Barreno, M., Nelson, B., Joseph, A. D., & Tygar, J. D. (2010). The security of machine learning. *Machine Learning*, 81(2), 121–148. <https://doi.org/10.1007/s10994-010-5188-5>
3. Barreno, M., Nelson, B., Sears, R., Joseph, A. D., & Tygar, J. D. (2006). Can machine learning be secure? In *Proceedings of the 2006 ACM Symposium on Information, Computer and Communications Security* (pp. 16–25). Taipei, Taiwan. <https://doi.org/10.1145/1128817.1128824>
4. Biggio, B., Nelson, B., & Laskov, P. (2012). Poisoning attacks against support vector machines. In *Proceedings of the 29th International Conference on Machine Learning* (pp. 1807–1814). Edinburgh, United Kingdom.
5. Biggio, B., & Roli, F. (2018). Wild patterns: Ten years after the rise of adversarial machine learning. *Pattern Recognition*, 84, 317–331. <https://doi.org/10.1016/j.patcog.2018.07.023>
6. Carlini, N., Jagielski, M., Choquette-Choo, C. A., Paleka, D., Pearce, W., Anderson, H., Terzis, A., Thomas, K., & Tramèr, F. (2024). Poisoning web-scale training datasets is practical. In *2024 IEEE Symposium on Security and Privacy* (pp. 407–425). San Francisco, CA. <https://doi.org/10.1109/SP54263.2024.00179>
7. Cinà, A. E., Grosse, K., Demontis, A., Vascon, S., Zellinger, W., Moser, B. A., Oprea, A., Biggio, B., Pelillo, M., & Roli, F. (2023). Wild patterns reloaded: A survey of machine learning security against training data poisoning. *ACM Computing Surveys*, 55(13s), 1–39. <https://doi.org/10.1145/3585385>
8. Cotroneo, D., Improta, C., Liguori, P., & Natella, R. (2024). Vulnerabilities in AI code generators: Exploring targeted data poisoning attacks. In *Proceedings of the 32nd*

- IEEE/ACM International Conference on Program Comprehension (pp. 280–292). Lisbon, Portugal. <https://doi.org/10.1145/3643916.3644416>
9. Cui, Y., & Widom, J. (2003). Lineage tracing for general data warehouse transformations. *The VLDB Journal*, 12(1), 41–58. <https://doi.org/10.1007/s00778-002-0083-8>
 10. Dalvi, N., Domingos, P., Mausam, Sanghai, S., & Verma, D. (2004). Adversarial classification. In *Proceedings of the Tenth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 99–108). Seattle, WA. <https://doi.org/10.1145/1014052.1014066>
 11. Dammak, S., Ghozzi, F., & Gargouri, F. (2019). ETL processes security modeling. *International Journal of Information System Modeling and Design*, 10(1), 60–84. <https://doi.org/10.4018/IJISMD.2019010104>
 12. Europski parlament i Vijeće Europske unije. (2024). Uredba (EU) 2024/1689 o utvrđivanju usklađenih pravila o umjetnoj inteligenciji (Akt o umjetnoj inteligenciji). *Službeni list Europske unije*. <https://eur-lex.europa.eu/eli/reg/2024/1689/oj>
 13. Goldblum, M., Tsipras, D., Xie, C., Chen, X., Schwarzschild, A., Song, D., Madry, A., Li, B., & Goldstein, T. (2022). Dataset security for machine learning: Data poisoning, backdoor attacks, and defenses. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(2), 1563–1580. <https://doi.org/10.1109/TPAMI.2022.3162397>
 14. Gosain, A., & Arora, A. (2015). Security issues in data warehouse: A systematic review. *Procedia Computer Science*, 48, 149–157. <https://doi.org/10.1016/j.procs.2015.04.164>
 15. Hartle, F., III, Mancini, S., & Kerry, E. (2025). Data poisoning 2018–2025: A systematic review of risks, impacts, and mitigation challenges. *Issues in Information Systems*, 25(4), 433–442. https://doi.org/10.48009/4_iis_2025_135
 16. Inmon, W. H. (2005). *Building the data warehouse* (4th ed.). Indianapolis, IN: Wiley.
 17. Jagielski, M., Oprea, A., Biggio, B., Liu, C., Nita-Rotaru, C., & Li, B. (2018). Manipulating machine learning: Poisoning attacks and countermeasures for regression learning. In *2018 IEEE Symposium on Security and Privacy* (pp. 19–35). San Francisco, CA. <https://doi.org/10.1109/SP.2018.00057>
 18. Kimball, R., & Caserta, J. (2004). *The data warehouse ETL toolkit*. Indianapolis, IN: Wiley.
 19. Koh, P. W., Steinhardt, J., & Liang, P. (2022). Stronger data poisoning attacks break data sanitization defenses. *Machine Learning*, 111(1), 1–47. <https://doi.org/10.1007/s10994-021-06119-y>
 20. Luca, M., & Zervas, G. (2016). Fake it till you make it: Reputation, competition, and Yelp review fraud. *Management Science*, 62(12), 3412–3427. <https://doi.org/10.1287/mnsc.2015.2304>
 21. OWASP Foundation. (2025). *AI Exchange: The world's AI security guide*. Retrieved June 11, 2026, from <https://owaspai.org/>
 22. Polyzotis, N., Zinkevich, M., Roy, S., Breck, E., & Whang, S. (2019). Data validation for machine learning. *Proceedings of Machine Learning and Systems*, 1, 334–347.
 23. Schelter, S., Lange, D., Schmidt, P., Celikel, M., Biessmann, F., & Grafberger, A. (2018). Automating large-scale data quality verification. *Proceedings of the VLDB Endowment*, 11(12), 1781–1794. <https://doi.org/10.14778/3229863.3229867>
 24. Shafahi, A., Huang, W. R., Najibi, M., Suci, O., Studer, C., Dumitras, T., & Goldstein, T. (2018). Poison frogs! Targeted clean-label poisoning attacks on neural networks. In *Advances in Neural Information Processing Systems 31* (pp. 6103–6113). Montréal, Canada.
 25. Spoczynski, M., Melara, M. S., & Szyller, S. (2025). Atlas: A framework for ML lifecycle provenance and transparency. *arXiv*. <https://doi.org/10.48550/arXiv.2502.19567>

26. Steinhardt, J., Koh, P. W., & Liang, P. (2017). Certified defenses for data poisoning attacks. In *Advances in Neural Information Processing Systems* 30 (pp. 3517–3529). Long Beach, CA.
27. Tian, Z., Cui, L., Liang, J., & Yu, S. (2022). A comprehensive survey on poisoning attacks and countermeasures in machine learning. *ACM Computing Surveys*, 55(8), 1–35. <https://doi.org/10.1145/3551636>
28. Vassiliadis, P. (2009). A survey of extract–transform–load technology. *International Journal of Data Warehousing and Mining*, 5(3), 1–27. <https://doi.org/10.4018/jdwm.2009070101>
29. Vassilev, A., Oprea, A., Fordyce, A., Anderson, H., Davies, X., & Hamin, M. (2025). Adversarial machine learning: A taxonomy and terminology of attacks and mitigations (NIST AI 100-2e2025). Gaithersburg, MD: National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.AI.100-2e2025>
30. Wang, R. Y., & Strong, D. M. (1996). Beyond accuracy: What data quality means to data consumers. *Journal of Management Information Systems*, 12(4), 5–33. <https://doi.org/10.1080/07421222.1996.11518099>
31. Zhao, P., Zhu, W., Jiao, P., Gao, D., & Wu, O. (2025). Data poisoning in deep learning: A survey. *arXiv*. <https://doi.org/10.48550/arXiv.2503.22759>

USPOREDNA ANALIZA DIMENZIJA RAVNOTEŽE PRIVATNOG I POSLOVNOG ŽIVOTA PREMA OBILJEŽJIMA ZAPOSLENIKA

NIKOLINA TUMPAK

Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
ntumpak22@student.foi.hr

LORENA PIKL

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

SAŽETAK

Ravnoteža privatnog i poslovnog života predstavlja važan aspekt upravljanja ljudskim potencijalima te se može razlikovati s obzirom na različita obilježja zaposlenika. Cilj rada je analizirati dimenzije ravnoteže privatnog i poslovnog života prema odabranim obilježjima zaposlenika, odnosno spolu, dobi, ukupnom radnom stažu te obilježjima putovanja na posao. Istraživanje je provedeno na uzorku od 120 ispitanika primjenom upitnika koji obuhvaća pet dimenzija ravnoteže privatnog i poslovnog života. Podaci su analizirani primjenom deskriptivne statistike, a prosječne vrijednosti pojedinih dimenzija uspoređene su prema odabranim obilježjima zaposlenika. Rezultati pokazuju različite obrasce prosječnih vrijednosti pojedinih dimenzija među promatranim skupinama ispitanika, pri čemu nijedna promatrana skupina nije ostvarila povoljnije prosječne vrijednosti na svim dimenzijama. Razlike su uočene i s obzirom na obilježja putovanja na posao, što upućuje na praktičnu relevantnost razmatranja vremenskih zahtjeva povezanih s putovanjem pri proučavanju ravnoteže privatnog i poslovnog života. Praktična vrijednost rada ogleda se u pružanju uvida koji organizacijama mogu pomoći pri prepoznavanju različitih potreba zaposlenika i razmatranju odgovarajućih oblika organizacijske podrške.

KLJUČNE RIJEČI: ravnoteža privatnog i poslovnog života, radna obilježja zaposlenika, demografska obilježja zaposlenika

1. UVOD

Ravnoteža privatnog i poslovnog života posljednjih godina postaje jedno od značajnijih područja interesa stručnjaka i istraživača iz područja upravljanja ljudskim potencijalima. Sve izraženiji poslovni zahtjevi, ubrzan razvoj tehnologije i povećana povezanost poslovne i privatne sfere života doveli su do potrebe za učinkovitijim usklađivanjem različitih životnih uloga zaposlenika (Greenhaus i Callalan, 2020.). Ravnoteža privatnog i poslovnog života

najčešće se definira kao sposobnost pojedinca da uspješno usklađuje poslovne obveze s privatnim životom uz minimalnu razinu konflikta između tih životnih područja (Delecta, 2011.; Sirgy i Lee, 2018.). Rezultati dosadašnjih istraživanja upućuju na postojanje razlika u percepciji ravnoteže privatnog i poslovnog života s obzirom na različita demografska (Björk-Fant, Nordmyr i Forsman, 2024.; Dupont, Giuliano i Godfroid, 2023.; Kashyap i Hoda, 2022.; Koreshi i Alpass, 2023.; Ramadhani, 2024.) i radna obilježja zaposlenika (Bai, Gopalan, Beutell i Ren, 2021.; Jain i Lyons, 2008.; Mokhtarian i Salomon, 2001.; Tao i He, 2021.; Watts i Urry, 2008.).

Polazeći od navedenih spoznaja, problem kojim se rad bavi odnosi se na razlike u iskazanim dimenzijama ravnoteže privatnog i poslovnog života među skupinama zaposlenika različitih demografskih i radnih obilježja. Iako su pojedina obilježja zaposlenika i njihova povezanost s ravnotežom privatnog i poslovnog života zastupljeni u prethodnim istraživanjima, u ovom se radu navedena problematika razmatra objedinjavanjem više obilježja zaposlenika, uključujući obilježja svakodnevnog putovanja na posao. Točnije, svrha rada jest pružiti uvid u ravnotežu privatnog i poslovnog života zaposlenika s obzirom na odabrana demografska i radna obilježja. U skladu s time, ciljevi rada su: prikazati rezultate pojedinih dimenzija ravnoteže privatnog i poslovnog života u promatranom uzorku zaposlenika; deskriptivno usporediti njihove prosječne vrijednosti s obzirom na spol, dob, radni staž i obilježja putovanja na posao; te na temelju uočenih obrazaca razmotriti praktične implikacije relevantne za upravljanje ljudskim potencijalima. Analiza je pritom deskriptivnog karaktera te nije usmjerena na utvrđivanje statističke značajnosti razlika ni uzročno-posljedičnih odnosa među promatranim obilježjima.

Stručni doprinos rada ogleda se u prikazu i usporedbi dimenzija ravnoteže privatnog i poslovnog života prema različitim obilježjima zaposlenika te u razmatranju praktične relevantnosti dobivenih rezultata za organizacije i menadžere. Nakon uvodnog dijela u radu se prikazuje pojam i važnost ravnoteže privatnog i poslovnog života te relevantne spoznaje prethodnih istraživanja. Potom se opisuju provedeno istraživanje i uzorak, prikazuju rezultati deskriptivne analize te se rezultati raspravljaju u kontekstu prethodnih istraživanja. Na kraju se iznose praktične implikacije, ograničenja rada i zaključna razmatranja.

2. RAVNOTEŽA PRIVATNOG I POSLOVNOG ŽIVOTA U SUVREMENOM RADNOM OKRUŽENJU

2.1. POJAM I VAŽNOST RAVNOTEŽE PRIVATNOG I POSLOVNOG ŽIVOTA

U suvremenom radnom okruženju ravnoteža privatnog i poslovnog života postaje sve važnije pitanje za zaposlenike i organizacije. Zaposlenici se svakodnevno suočavaju s različitim zahtjevima koji proizlaze iz njihovih poslovnih i privatnih uloga. Usklađivanje tih zahtjeva može predstavljati izazov, osobito kada se zahtjevi različitih životnih uloga međusobno preklapaju ili dolaze u sukob.

Sirgy i Lee (2018.) ravnotežu između privatnog i poslovnog života definiraju kao angažman pojedinca u višestrukim ulogama uz minimalan sukob između poslovnih i privatnih životnih uloga. Iako u literaturi postoje različiti pristupi definiranju ravnoteže privatnog i poslovnog života, zajedničko im je razmatranje odnosa između zahtjeva poslovnog i privatnog područja života (Delecta, 2011.; Lockwood, 2003.). Pojedinaac tijekom života istodobno preuzima

različite poslovne i privatne uloge, zbog čega njihovo međusobno usklađivanje predstavlja važan aspekt ravnoteže privatnog i poslovnog života.

Odgovarajuća organizacija i raspodjela poslovnih obveza mogu zaposlenicima olakšati usklađivanje poslovnih i privatnih zahtjeva, a organizacijama pridonijeti učinkovitijem upravljanju radnim procesima. Pritom postizanje ravnoteže ne ovisi isključivo o zaposleniku, već i o uvjetima rada te podršci koju pruža organizacija. Organizacije mogu pridonijeti usklađivanju poslovnog i privatnog života zaposlenika primjenom različitih praksi, poput fleksibilnog radnog vremena, skraćenog radnog vremena i drugih oblika podrške zaposlenicima (Bahtijarević-Šiber, 1999.).

Narušena ravnoteža privatnog i poslovnog života može biti povezana s nepovoljnim ishodima za zaposlenike i organizacije, dok uspješnije usklađivanje poslovnih i privatnih zahtjeva može biti povezano s većim zadovoljstvom, boljim zdravljem i povoljnijim radnim ishodima (Mladenović, 2020.). Važnost ravnoteže privatnog i poslovnog života stoga se ogleda u njezinoj povezanosti s dobrobiti zaposlenika, ali i s ishodima relevantnima za organizaciju. Mladenović (2020.) navodi da su među pozitivnim učincima ravnoteže privatnog i poslovnog života bolja kontrola nad poslovnim i privatnim životom, kvalitetniji međuljudski odnosi na poslu i izvan njega, bolje fizičko i mentalno zdravlje, niža razina stresa na poslu, veće zadovoljstvo poslom, veća produktivnost te manja namjera napuštanja organizacije. Navedeno pokazuje da ravnoteža privatnog i poslovnog života može imati važnu ulogu ne samo za kvalitetu života zaposlenika nego i za njegovo funkcioniranje u radnom okruženju.

2.2. ISTRAŽIVANJA RAVNOTEŽE PRIVATNOG I POSLOVNOG ŽIVOTA S OBZIROM NA OBILJEŽJA ZAPOSLENIKA

Brojna istraživanja provedena su s ciljem utvrđivanja povezanosti demografskih i radnih obilježja s ravnotežom privatnog i poslovnog života zaposlenika. Promjene na radnom mjestu i u demografskoj strukturi zaposlenika tijekom posljednjih nekoliko desetljeća dovele su do povećanog interesa za razumijevanje granice i međusobnog odnosa između privatnog i poslovnog života zaposlenika (Kossek, Yu, Pichler i Xu, 2026.).

Björk-Fant i sur. (2024.) pokazali su da žene, osobito u fazama života koje uključuju brigu o djeci, češće prijavljuju poteškoće u postizanju ravnoteže između privatnog i poslovnog života, dok Dupont i sur. (2023.) naglašavaju da je raspodjela kućanskih obveza i dalje rodno obilježena te da žene preuzimaju veći dio neplaćenog rada, što utječe na usklađivanje poslovnih i privatnih uloga. Slično tome, istraživanja pokazuju da se zaposlene žene u dobi od 25 do 50 godina često suočavaju s izazovima u postizanju ravnoteže između privatnog i poslovnog života (Desai, 2015.). Nadalje, istraživanja pokazuju da mlađe osobe, osobito zbog roditeljskih obveza i razvoja karijere, češće doživljavaju poteškoće u usklađivanju poslovnih i privatnih zahtjeva nego stariji zaposlenici (Crompton i Lyonette, 2006.). Nasuprot tome, stariji zaposlenici uglavnom iskazuju veće zadovoljstvo postignutom ravnotežom između privatnog i poslovnog života, što se dijelom pripisuje većoj fleksibilnosti tržišta rada i boljoj prilagodbi radnih uvjeta njihovim potrebama (Kashyap i Hoda, 2022.; Penner, Perun i Steuerle, 2003.). Međutim, i oni se mogu susretati s preprekama koje proizlaze iz stereotipa i diskriminacije na radnom mjestu (Koreshi i Alpess, 2023.).

Nadalje, istraživanja upućuju na to da zaposlenici s više radnog staža često razvijaju učinkovitije strategije upravljanja radnim i privatnim obvezama te bolje koriste organizacijske resurse koji im pomažu u usklađivanju različitih životnih uloga (Choudhary i Singh, 2016.;

Ramadhani, 2024.). Prema tome, može se zaključiti kako se zaposlenici s manje radnog staža mogu suočavati s većim izazovima zbog prilagodbe radnom okruženju, razvoja karijere i izgradnje profesionalne uloge, što može otežati postizanje ravnoteže između privatnog i poslovnog života.

Na temelju spoznaja prethodnih istraživanja u ovom su radu za usporedbu odabrani spol, dob i radni staž kao obilježja zaposlenika koja mogu biti relevantna za način na koji zaposlenici doživljavaju usklađenost poslovnog i privatnog života. Uz navedena obilježja, u analizu su uključena i obilježja svakodnevnog putovanja na posao. Njihovo uključivanje proizlazi iz činjenice da putovanje predstavlja dodatni vremenski zahtjev povezan s radom, iako se odvija izvan samog radnog vremena. Istraživanja pokazuju da dulje vrijeme provedeno na putovanju smanjuje vrijeme dostupno za aktivnosti izvan posla (Bai i sur., 2021.; Tao i He, 2021.) te vrijeme provedeno s obitelji (Tao i He, 2021.), zbog čega je negativno povezano s ravnotežom privatnog i poslovnog života. Međutim, taj odnos nije jednoznačan. Ljudi prihvaćaju duga putovanja na posao iz različitih razloga, a neki ih čak ne doživljavaju negativno. Kvalitativna istraživanja pokazala su da pojedinci vrijeme provedeno na putovanju mogu smatrati ugodnim jer ono predstavlja prijelaz između poslovnog i obiteljskog života (Jain i Lyons, 2008.; Watts i Urry, 2008.). Također, zaposlenici vrijeme putovanja na posao mogu koristiti za opuštanje, promišljanje ili mentalno „prebacivanje” između poslovnih i privatnih uloga, što može ublažiti negativne učinke putovanja na posao (Mokhtarian i Salomon, 2001.).

3. OPIS ISTRAŽIVANJA I UZORAK

3.1. INSTRUMENT ISTRAŽIVANJA

Cilj istraživanja bio je ispitati ravnotežu privatnog i poslovnog života te to usporediti s obzirom na obilježja zaposlenika. U tu je svrhu napravljen anketni upitnik u dva dijela. Prvi dio odnosio se na pitanja vezana uz obilježja zaposlenika, dok se drugi dio odnosio na tvrdnje vezane uz ravnotežu privatnog i poslovnog života. Kako bi se ispitala ravnoteža privatnog i poslovnog života korišten je validirani mjerni instrument koji se sastojao od 46 tvrdnji raspoređenih u pet dimenzija koji su razvili Banu i Duraipandian (2014.). Zaposlenici su mjernom ljestvicom Likertovog tipa od 1 do 5 („1“ – u potpunosti se ne slažem; „5“ – u potpunosti se slažem) trebali iskazati stupanj svojega (ne)slaganja s navedenom tvrdnjom.

Dimenzije ravnoteže privatnog i poslovnog života koje su ispitane u radu su sljedeće: podrška na radnom mjestu, uključenost posla u privatni život, uključenost privatnog života u posao, zadovoljstvo ravnotežom privatnog i poslovnog života te poboljšana učinkovitost na radnom mjestu. Pouzdanost mjernog instrumenta u ovom istraživanju provjerena je izračunom Cronbachova alfa koeficijenta zasebno za svaku od pet dimenzija. Dobivene vrijednosti iznosile su $\alpha = 0,913$ za dimenziju podrške na radnom mjestu (D1), $\alpha = 0,940$ za uključenost posla u privatni život (D2), $\alpha = 0,962$ za uključenost privatnog života u posao (D3), $\alpha = 0,947$ za zadovoljstvo ravnotežom privatnog i poslovnog života (D4) te $\alpha = 0,883$ za poboljšanu učinkovitost na radnom mjestu (D5). Dobivene vrijednosti upućuju na visoku unutarnju konzistentnost svih pet dimenzija korištenog mjernog instrumenta.

Obrada podataka provedena je primjenom deskriptivne statistike. Za pojedine dimenzije ravnoteže privatnog i poslovnog života izračunate su prosječne vrijednosti koje su zatim deskriptivno uspoređene s obzirom na odabrana obilježja zaposlenika. Budući da nisu provedeni inferencijalni statistički testovi, uočene razlike u prosječnim vrijednostima odnose

se isključivo na promatrani uzorak te se ne interpretiraju kao statistički značajne razlike među skupinama.

3.2. ODABIR UZORKA, PRIKUPLJANJE I ANALIZA PODATAKA

U istraživanju je korišten online anketni upitnik, a primarni podaci prikupljeni su od veljače do svibnja 2025. godine. Anketni upitnik, kao instrument za prikupljanje primarnih podataka, distribuirao se putem društvenih mreža. U istraživanju su mogle sudjelovati isključivo zaposlene osobe, što je bilo definirano kao jedan od kriterija za sudjelovanje. U ovome istraživanju korišten je namjerni prigodni uzorak ispitanika. Konačni uzorak obuhvatio je 120 ispitanika. Prikupljanje podataka provedeno je putem online anketnog upitnika izrađenog u alatu Google Obrasci (engl. *Google Forms*), što je ispitanicima omogućilo jednostavan i anoniman pristup istraživanju.

Tablica 1. prikazuje obilježja ispitanika po odabranim varijablama (spol, dob, radni staž, mjesto prebivališta i vrijeme putovanja do radnog mjesta). Prema spolu ispitanika u provedenom istraživanju sudjelovalo je 62,5% žena i 37,5% muškaraca. Nadalje, najveći broj ispitanika (60%) ima 35 godina i manje te 38,3% ispitanika ima više od 10 godina radnog staža. Važno je spomenuti kako 65% ispitanika putuje na radno mjesto izvan mjesta prebivališta, dok 35% ispitanika ne putuje te se radno mjesto nalazi unutar mjesta njihova prebivališta. Nastavno na prethodnu varijablu, u posljednjoj varijabli koja se tiče vremena putovanja do radnog mjesta, 53,4% ispitanika označilo je da im je potrebno manje od 30 minuta, između 30 i 60 minuta potrebno je 30,8% ispitanika, a više od 60 minuta potrebno je 15,8% ispitanika. Prema provedenom istraživanju, među ispitanicima prevladavaju žene (62,5%), osobe u dobi od 35 godina ili manje (60%), ispitanici s više od 10 godina radnog staža (38,3%), osobe čije se radno mjesto nalazi izvan mjesta prebivališta (65%) te osobe kojima je potrebno manje od 30 minuta vremena putovanja do radnog mjesta (53,4%).

Tablica 1. Obilježja ispitanika

Varijabla	Kategorija	%
Spol ispitanika	ženski	62,5%
	muški	37,5%
Dob ispitanika	35 i manje	60%
	36 do 45 godina	14,2%
	46 do 55 godina	19,2%
	56 ili više godina	6,7%
Radni staž ispitanika	manje od 3 godine	21,7%
	3 do 6 godina	17,5%
	7 do 10 godina	22,5%
	više od 10 godina	38,3%
Radno mjesto nalazi se izvan mjesta prebivališta	da	65%
	ne	35%
Vrijeme putovanja do radnog mjesta	manje od 30 minuta	53,4%
	između 30 i 60 minuta	30,8%
	više od 60 minuta	15,8%

Izvor: Vlastita izrada autorica

4. REZULTATI

U Tablici 2. prikazane su prosječne vrijednosti dimenzija ravnoteže privatnog i poslovnog života prema odabranim obilježjima ispitanika: spolu, dobi, ukupnom radnom stažu te obilježjima putovanja na posao. Rezultati su interpretirani u skladu sa smjerom pojedine dimenzije, pri čemu niže vrijednosti na dimenzijama D2 – Uključenost posla u privatni život i D3 – Uključenost privatnog života u posao, a više vrijednosti na dimenzijama D1 – Podrška na radnom mjestu, D4 – Zadovoljstvo ravnotežom privatnog i poslovnog života i D5 – Poboljšana učinkovitost na radnom mjestu, upućuju na povoljniju ravnotežu privatnog i poslovnog života. S obzirom na deskriptivni karakter analize, prikazane razlike u prosječnim vrijednostima odnose se na promatrani uzorak i ne predstavljaju statistički potvrđene razlike među skupinama.

Kod dimenzije D1 – *Podrška na radnom mjestu* uočena je nešto viša prosječna vrijednost kod muškaraca ($M = 3,51$) u odnosu na žene. Promatrano prema dobi, najniža prosječna vrijednost zabilježena je kod ispitanika u dobi od 36 do 45 godina, dok je najviša zabilježena kod ispitanika u dobi od 56 godina ili više ($M = 3,64$). S obzirom na ukupni radni staž, najviša prosječna vrijednost zabilježena je kod ispitanika s manje od tri godine radnog staža ($M = 3,56$), dok su ispitanici s više od deset godina radnog staža ostvarili nižu prosječnu vrijednost. Razlike su uočene i s obzirom na obilježja putovanja na posao. Ispitanici koji putuju na radno mjesto izvan mjesta prebivališta ostvarili su višu prosječnu vrijednost ($M = 3,47$) od ispitanika koji ne putuju izvan mjesta prebivališta. Prema vremenu provedenom na putovanju, najviša prosječna vrijednost dimenzije D1 zabilježena je kod ispitanika koji na posao putuju dulje od 60 minuta ($M = 3,71$).

Kod dimenzije D2 – *Uključenost posla u privatni život* niža prosječna vrijednost zabilježena je kod žena ($M = 2,94$) nego kod muškaraca, što prema smjeru ove dimenzije upućuje na manju uključenost posla u privatni život u promatranom uzorku žena. Prema dobi, najniža prosječna vrijednost zabilježena je kod ispitanika u dobi od 35 godina ili manje ($M = 2,86$), dok je najviša vrijednost zabilježena kod ispitanika u dobi od 56 godina ili više. S obzirom na ukupni radni staž, najniža prosječna vrijednost zabilježena je kod ispitanika s manje od tri godine radnog staža ($M = 2,48$), dok je najviša zabilježena kod ispitanika sa sedam do deset godina radnog staža. Ispitanici koji ne putuju na posao izvan mjesta prebivališta ostvarili su nižu prosječnu vrijednost ($M = 2,75$) od ispitanika koji putuju izvan mjesta prebivališta. Promatrano prema vremenu putovanja, najniža prosječna vrijednost zabilježena je kod ispitanika koji putuju manje od 30 minuta ($M = 2,73$), dok je najviša zabilježena kod ispitanika koji na posao putuju dulje od 60 minuta.

Kod dimenzije D3 – *Uključenost privatnog života u posao* žene su ostvarile nižu prosječnu vrijednost ($M = 2,49$) od muškaraca. Promatrano prema dobi, najniža prosječna vrijednost zabilježena je kod ispitanika u dobi od 35 godina ili manje ($M = 2,54$), dok je najviša zabilježena kod ispitanika u dobi od 56 godina ili više. Prema ukupnom radnom stažu, najnižu prosječnu vrijednost ostvarili su ispitanici s manje od tri godine radnog staža ($M = 2,22$), dok je kod ispitanika s duljim radnim stažem zabilježena viša prosječna vrijednost. Razlike u prosječnim vrijednostima vidljive su i prema obilježjima putovanja na posao. Ispitanici koji ne putuju na radno mjesto izvan mjesta prebivališta ostvarili su nižu prosječnu vrijednost ($M = 2,32$) od onih koji putuju. Prema vremenu putovanja, najniža prosječna vrijednost zabilježena je kod ispitanika koji putuju manje od 30 minuta ($M = 2,22$), dok je najviša zabilježena kod ispitanika koji putuju dulje od 60 minuta.

Kod dimenzije D4 – *Zadovoljstvo ravnotežom privatnog i poslovnog života* muškarci su ostvarili nešto višu prosječnu vrijednost ($M = 3,76$) od žena. Prema dobi, najviša prosječna vrijednost zabilježena je kod ispitanika u dobi od 56 godina ili više ($M = 3,75$), dok je najniža zabilježena kod ispitanika u dobi od 46 do 55 godina. S obzirom na ukupni radni staž, najviša prosječna vrijednost zabilježena je kod ispitanika s manje od tri godine radnog staža ($M = 3,90$), dok je najniža zabilježena kod ispitanika s tri do šest godina radnog staža. Ispitanici koji ne putuju na posao izvan mjesta prebivališta ostvarili su višu prosječnu vrijednost zadovoljstva ravnotežom privatnog i poslovnog života ($M = 3,82$) od ispitanika koji putuju. Promatrano prema vremenu putovanja, najviša prosječna vrijednost zabilježena je kod ispitanika koji putuju manje od 30 minuta ($M = 3,77$).

Kod dimenzije D5 – *Poboljšana učinkovitost na radnom mjestu* žene su ostvarile nešto višu prosječnu vrijednost ($M = 3,98$) od muškaraca. Prema dobi, najviša prosječna vrijednost zabilježena je kod ispitanika u dobi od 35 godina ili manje ($M = 4,05$), dok je najniža zabilježena kod ispitanika u dobi od 56 godina ili više. S obzirom na ukupni radni staž, najviša prosječna vrijednost zabilježena je kod ispitanika s tri do šest godina radnog staža ($M = 4,30$), dok su ispitanici s više od deset godina radnog staža ostvarili najnižu prosječnu vrijednost. Ispitanici koji ne putuju na posao izvan mjesta prebivališta ostvarili su nešto višu prosječnu vrijednost ($M = 4,06$) od ispitanika koji putuju. Međutim, kada se promatra vrijeme putovanja među ispitanicima koji putuju na posao, najviša prosječna vrijednost zabilježena je kod onih koji putuju dulje od 60 minuta ($M = 4,12$), dok je niža vrijednost zabilježena kod ispitanika koji putuju između 30 i 60 minuta.

Tablica 2. Prosječne vrijednosti dimenzija ravnoteže privatnog i poslovnog života prema obilježjima ispitanika

Varijabla	Kategorija	D1	D2	D3	D4	D5
Spol ispitanika	ženski	3,42	2,94	2,49	3,62	3,98
	muški	3,51	3,11	2,90	3,76	3,91
Dob ispitanika	35 i manje	3,44	2,86	2,54	3,72	4,05
	36 do 45 godina	3,32	3,13	2,90	3,63	3,82
	46 do 55 godina	3,53	3,16	2,66	3,54	3,84
	56 ili više godina	3,64	3,57	3,01	3,75	3,71
Radni staž ispitanika	manje od 3 godine	3,56	2,48	2,22	3,90	3,99
	3 do 6 godina	3,50	2,77	2,29	3,55	4,30
	7 do 10 godina	3,35	3,46	3,26	3,72	3,96
	više od 10 godina	3,43	3,15	2,69	3,58	3,77
Radno mjesto nalazi se izvan mjesta prebivališta	da	3,47	3,15	2,82	3,59	3,90
	ne	3,42	2,75	2,32	3,82	4,06
Vrijeme putovanja do radnog mjesta	manje od 30 minuta	3,36	2,73	2,22	3,77	4,03
	između 30 i 60 minuta	3,49	3,23	3,00	3,47	3,73
	više od 60 minuta	3,71	3,51	3,40	3,76	4,12

Napomena. D1 = Podrška na radnom mjestu; D2 = Uključenost posla u privatni život; D3 = Uključenost privatnog života u posao; D4 = Zadovoljstvo ravnotežom privatnog i poslovnog života; D5 = Poboljšana učinkovitost na radnom mjestu.

Izvor: Vlastita izrada autorica

5. RASPRAVA

Deskriptivna analiza pokazala je različite obrasce prosječnih vrijednosti dimenzija ravnoteže privatnog i poslovnog života s obzirom na promatrana obilježja zaposlenika. Uočene razlike potrebno je interpretirati u okviru promatranog uzorka jer u istraživanju nisu provedeni inferencijalni statistički testovi.

S obzirom na spol, u promatranom uzorku nisu uočeni potpuno jednaki obrasci u svim dimenzijama. Muškarci su ostvarili nešto višu prosječnu vrijednost podrške na radnom mjestu i zadovoljstva ravnotežom privatnog i poslovnog života, dok su žene ostvarile povoljnije prosječne vrijednosti na dimenzijama uključenosti posla u privatni život, uključenosti privatnog života u posao i poboljšane učinkovitosti na radnom mjestu. Takvi rezultati pokazuju da odnos između spola i ravnoteže privatnog i poslovnog života nije opravdano promatrati jednoznačno. Prethodna istraživanja pokazuju da se žene mogu suočavati s većim poteškoćama u postizanju ravnoteže privatnog i poslovnog života, osobito zbog obiteljskih i kućanskih obveza (Björk-Fant i sur., 2024.; Desai, 2015.; Dupont i sur., 2023.). Rezultati ovog istraživanja djelomično odstupaju od navedenih spoznaja jer su žene ostvarile povoljnije prosječne vrijednosti na tri od pet promatranih dimenzija, što potvrđuje važnost zasebnog promatranja pojedinih dimenzija ravnoteže.

Razlike u prosječnim vrijednostima uočene su i među dobnim skupinama. Ispitanici u dobi od 56 godina ili više ostvarili su najvišu prosječnu vrijednost podrške na radnom mjestu i zadovoljstva ravnotežom privatnog i poslovnog života, ali istodobno i nepovoljnije vrijednosti pojedinih dimenzija uključenosti poslovnog i privatnog života. S druge strane, kod ispitanika u dobi od 35 godina ili manje zabilježene su povoljnije prosječne vrijednosti uključenosti posla u privatni život, uključenosti privatnog života u posao i poboljšane učinkovitosti na radnom mjestu. Dobiveni rezultati djelomično su u skladu s prethodnim istraživanjima prema kojima stariji zaposlenici iskazuju veće zadovoljstvo ravnotežom privatnog i poslovnog života (Kashyap i Hoda, 2022.; Penner i sur., 2003.). Međutim, suprotno spoznajama da mlađe osobe mogu imati više poteškoća u postizanju ravnoteže (Crompton i Lyonette, 2006.), ispitanici do 35 godina u promatranom su uzorku ostvarili povoljnije vrijednosti na pojedinim dimenzijama.

Sličan obrazac vidljiv je kod ukupnog radnog staža. Ispitanici s manje od tri godine radnog staža ostvarili su najvišu prosječnu vrijednost podrške na radnom mjestu te povoljnije vrijednosti uključenosti posla u privatni život i uključenosti privatnog života u posao. Ujedno su ostvarili i najvišu prosječnu vrijednost zadovoljstva ravnotežom privatnog i poslovnog života. Međutim, kod dimenzije poboljšane učinkovitosti na radnom mjestu najviša prosječna vrijednost zabilježena je kod ispitanika s tri do šest godina radnog staža. Rezultati stoga pokazuju da se prosječne vrijednosti pojedinih dimenzija razlikuju među skupinama s različitim radnim stažem. Dobiveni rezultati odstupaju od prethodnih istraživanja prema kojima zaposlenici s više radnog staža učinkovitije usklađuju poslovne i privatne obveze (Choudhary i Singh, 2016.; Ramadhani, 2024.). U ovom su istraživanju zaposlenici s manje od tri godine radnog staža ostvarili povoljnije vrijednosti na četiri od pet promatranih dimenzija.

Posebno su zanimljivi rezultati povezani s putovanjem na posao. Ispitanici koji ne putuju izvan mjesta prebivališta ostvarili su povoljnije prosječne vrijednosti na dimenzijama uključenosti posla u privatni život, uključenosti privatnog života u posao, zadovoljstva ravnotežom privatnog i poslovnog života i poboljšane učinkovitosti na radnom mjestu. Takav

je obrazac u skladu sa spoznajama prethodnih istraživanja prema kojima vrijeme provedeno na putovanju može smanjiti vrijeme dostupno za aktivnosti izvan posla i vrijeme provedeno s obitelji (Bai i sur., 2021.; Tao i He, 2021.).

Nadalje, rezultati povezani s putovanjem nisu potpuno jednoznačni. Ispitanici koji putuju dulje od 60 minuta ostvarili su najvišu prosječnu vrijednost podrške na radnom mjestu, a među ispitanicima koji putuju na posao ostvarili su i najvišu prosječnu vrijednost poboljšane učinkovitosti na radnom mjestu. Prethodna istraživanja također pokazuju da putovanje na posao ne mora imati isključivo negativnu ulogu. Vrijeme putovanja pojedincima može predstavljati prijelaz između poslovnog i privatnog područja života te prostor za odmak od pojedine životne uloge (Jain i Lyons, 2008.; Mokhtarian i Salomon, 2001.; Watts i Urry, 2008.). Međutim, budući da razlozi putovanja, aktivnosti tijekom putovanja i doživljaj samog putovanja nisu bili predmet ovog istraživanja, dobivene rezultate nije moguće objasniti tim čimbenicima. Oni predstavljaju moguća objašnjenja iz prethodne literature koja bi bilo korisno dodatno ispitati u budućim istraživanjima.

Promatrani rezultati u cjelini pokazuju da se pojedina obilježja zaposlenika ne povezuju na jednak način sa svim dimenzijama ravnoteže privatnog i poslovnog života. Upravo zbog višedimenzionalnosti ovoga koncepta korisno je pojedine dimenzije promatrati zasebno, umjesto ravnotežu privatnog i poslovnog života svoditi na jednu ukupnu procjenu. Za organizacijsku praksu takav pristup može biti koristan jer upućuje na to da potrebe zaposlenika povezane s usklađivanjem poslovnog i privatnog života mogu biti različite među skupinama zaposlenika.

6. PRAKTIČNE IMPLIKACIJE

Rezultati provedene deskriptivne analize mogu poslužiti kao polazište za razmatranje praksi upravljanja ljudskim potencijalima usmjerenih na usklađivanje poslovnog i privatnog života zaposlenika. Uočene razlike u prosječnim vrijednostima pojedinih dimenzija s obzirom na spol, dob, radni staž i obilježja putovanja na posao upućuju na to da potrebe zaposlenika povezane s ravnotežom privatnog i poslovnog života ne moraju biti jednake među različitim skupinama zaposlenika. Stoga organizacije pri oblikovanju mjera podrške mogu uzeti u obzir različita obilježja i potrebe zaposlenika, umjesto primjene jednakih rješenja za sve zaposlenike.

Posebnu pozornost moguće je usmjeriti na organizacijsku podršku zaposlenicima. Rezultati pokazuju razlike u prosječnim vrijednostima dimenzije podrške na radnom mjestu među promatranim skupinama, što upućuje na praktičnu važnost praćenja načina na koji različite skupine zaposlenika doživljavaju podršku u radnom okruženju. Organizacije mogu periodično ispitivati potrebe zaposlenika i njihovo zadovoljstvo postojećim oblicima podrške te na temelju prikupljenih informacija prilagođavati svoje prakse upravljanja ljudskim potencijalima.

Rezultati povezani s putovanjem na posao također mogu biti relevantni za organizacijsku praksu. U promatranom uzorku ispitanici koji ne putuju na posao izvan mjesta prebivališta ostvarili su povoljnije prosječne vrijednosti na više promatranih dimenzija ravnoteže privatnog i poslovnog života. Budući da vrijeme putovanja predstavlja dodatni vremenski zahtjev povezan s radom, organizacije mogu razmotriti potrebe zaposlenika koji svakodnevno dulje putuju na posao. Ovisno o prirodi posla i organizacijskim mogućnostima, to može

uključivati razmatranje fleksibilnijeg početka i završetka radnog vremena ili drugih organizacijskih rješenja kojima se zaposlenicima može olakšati usklađivanje poslovnih i privatnih obveza.

Dobiveni rezultati u praktičnom smislu prije svega naglašavaju važnost prepoznavanja različitih potreba zaposlenika. Umjesto pretpostavke da će određena mjera jednako odgovarati svim zaposlenicima, organizacijama može biti korisno kontinuirano pratiti potrebe zaposlenika te razvijati oblike podrške prilagođene obilježjima radnog mjesta i mogućnostima organizacije. Takav pristup može predstavljati osnovu za oblikovanje praksi upravljanja ljudskim potencijalima usmjerenih na lakše usklađivanje poslovnog i privatnog života.

7. ZAKLJUČAK

Ravnoteža privatnog i poslovnog života predstavlja važan aspekt upravljanja ljudskim potencijalima jer je povezana s mogućnošću zaposlenika da usklađuju zahtjeve poslovnog i privatnog područja života. Cilj ovog rada bio je analizirati dimenzije ravnoteže privatnog i poslovnog života s obzirom na odabrana obilježja zaposlenika, odnosno spol, dob, ukupni radni staž te obilježja putovanja na posao.

Provedena deskriptivna analiza pokazala je različite obrasce prosječnih vrijednosti pojedinih dimenzija s obzirom na promatrana obilježja zaposlenika. Pritom nijedna skupina zaposlenika nije ostvarila povoljnije vrijednosti na svim promatranim dimenzijama. Rezultati povezani s putovanjem na posao također nisu bili potpuno jednoznačni. Ispitanici koji ne putuju izvan mjesta prebivališta ostvarili su povoljnije prosječne vrijednosti na više dimenzija, dok su kod pojedinih dimenzija povoljnije vrijednosti zabilježene i među ispitanicima koji dulje putuju. Navedeno dodatno upućuje na potrebu zasebnog promatranja različitih dimenzija ravnoteže privatnog i poslovnog života.

Praktična vrijednost rada ogleda se u ukazivanju na različite obrasce ravnoteže privatnog i poslovnog života među promatranim skupinama zaposlenika. Za organizacije to može biti korisno pri razmatranju potreba zaposlenika i oblikovanju praksi upravljanja ljudskim potencijalima. Rezultati posebno upućuju na važnost organizacijske podrške i uzimanja u obzir obilježja svakodnevnog putovanja na posao. Međutim, budući da istraživanjem nisu ispitivani učinci konkretnih organizacijskih mjera, na temelju dobivenih rezultata nije moguće zaključivati o učinkovitosti pojedinih praksi usmjerenih na poboljšanje ravnoteže privatnog i poslovnog života.

Pri interpretaciji rezultata potrebno je uzeti u obzir nekoliko ograničenja. Istraživanje je provedeno na prigodnom uzorku od 120 ispitanika, zbog čega rezultate nije moguće generalizirati na širu populaciju zaposlenika. Pojedine skupine ispitanika nisu jednako zastupljene, što također treba uzeti u obzir pri usporedbi njihovih prosječnih vrijednosti. Podaci se temelje na samoprocjenama ispitanika, pa odgovori odražavaju njihovu subjektivnu percepciju ravnoteže privatnog i poslovnog života. Dodatno ograničenje proizlazi iz primjene deskriptivne statističke analize. Usporedbe među skupinama temelje se na prosječnim vrijednostima pojedinih dimenzija bez primjene inferencijalnih statističkih testova. Stoga se uočene razlike odnose isključivo na promatrani uzorak te na temelju njih nije moguće zaključivati o statističkoj značajnosti razlika niti o uzročno-posljedičnim odnosima između obilježja zaposlenika i ravnoteže privatnog i poslovnog života. Također, istraživanjem nisu obuhvaćeni pojedini čimbenici koji bi mogli biti relevantni za interpretaciju rezultata, poput

vrste zanimanja, organizacijskih uvjeta rada, obiteljskih okolnosti, načina putovanja na posao ili subjektivnog doživljaja putovanja.

Buduća istraživanja mogu uključiti veće i raznolikije uzorke zaposlenika te primjenu inferencijalnih statističkih postupaka kako bi se detaljnije ispitala razlike među skupinama. Korisno bi bilo uključiti i dodatna obilježja radnog i privatnog okruženja zaposlenika te detaljnije istražiti povezanost putovanja na posao s pojedinim dimenzijama ravnoteže privatnog i poslovnog života. Time bi se omogućilo potpunije razumijevanje čimbenika povezanih s usklađivanjem poslovnih i privatnih obveza zaposlenika.

REFERENCE

1. Bahtijarević-Šiber, F. (1999.). *Management ljudskih potencijala*. Golden marketing.
2. Bai, B., Gopalan, N., Beutell, N. i Ren, F. (2021.). Impact of Absolute and Relative Commute Time on Work–Family Conflict: Work Schedule Control, Child Care Hours, and Life Satisfaction. *Journal of Family and Economic Issues*, 42(4), 586–600. <https://doi.org/10.1007/s10834-021-09752-w>
3. Banu, A. R. i Duraipandian, K. (2014.). Development of an Instrument to Measure Work Life Balance of it Professionals in Chennai. *International Journal of Management*, 5(11).
4. Björk-Fant, J. M., Nordmyr, J. i Forsman, A. K. (2024.). Work-life balance and the psychosocial work environment in Finnish working life: The case of gender and family life stages. *WORK*, 79(4), 1741–1752. <https://doi.org/10.3233/WOR-230166>
5. Choudhary, N. i Singh, N. (2016.). Work-Family Balance as per Life Stage and Total Experience: An Empirical Study Among Officers of Defense (Central Public Sector Enterprises) in Bangalore. *The IUP Journal of Organizational Behavior*, XV, 49–70.
6. Crompton, R. i Lyonette, C. (2006.). Work-Life ‘Balance’ in Europe. *Acta Sociologica*, 49(4), 379–393. <https://doi.org/10.1177/0001699306071680>
7. Delecta, P. (2011.). Work life balance. *International Journal of Current Research*, 3(4), 186–189.
8. Desai, R. (2015.). A Study on Work Life Balance of Female at Bardoli Region. *International Journal of Advanced Research in Management and Social Sciences*, 4(6).
9. Dupont, C., Giuliano, R. i Godfroid, C. (2023.). Teleworking, task sharing, and work-life balance: A gender issue? Theoretical approach. *Journal of Economics and Management*, 45(1), 374–412. <https://doi.org/10.22367/jem.2023.45.15>
10. Greenhaus, J. H. i Callalan, G. A. (2020.). Implications of the Changing Nature of Work for the Interface between Work and Nonwork Roles. U B. J. Hoffman, L. A. Wegman, i M. K. Shoss (Ur.), *The Cambridge Handbook of the Changing Nature of Work* (str. 467–488). Cambridge: Cambridge University Press. <https://doi.org/10.1017/9781108278034.022>
11. Jain, J. i Lyons, G. (2008.). The gift of travel time. *Journal of Transport Geography*, 16(2), 81–89. <https://doi.org/10.1016/j.jtrangeo.2007.05.001>
12. Kashyap, E. i Hoda, C. T. (2022.). ASSESSING THE ROLE OF DEMOGRAPHIC FACTORS ON WORK LIFE BALANCE OF IT PROFESSIONALS IN DELHI-NCR. *ShodhKosh: Journal of Visual and Performing Arts*, 3(2), 1248–1252. <https://doi.org/10.29121/shodhkosh.v3.i2.2022.5339>
13. Koreshi, S. Y. i Alpass, F. (2023.). Understanding the use of Flexible Work Arrangements Among Older New Zealand Caregivers. *Journal of Applied Gerontology*, 42(5), 1045–1055. <https://doi.org/10.1177/07334648231152153>

14. Kossek, E. E., Yu, A., Pichler, S. i Xu, J. (2026.). Employee Age and the Work–Family Interface: A Meta-Analysis and Framework Integrating Life Span and Life Course Perspectives. *Human Resource Management*, 65(1), 39–62. <https://doi.org/10.1002/hrm.70007>
15. Lockwood, N. (2003.). *Work/life Balance: Challenges and Solutions*. Society for Human Resource Management.
16. Mladenović, M. (2020.). Equilibrium between business and private life of employees and managers: Benefits for balance of life and their effects. *Ekonomski izazovi*, 9(17), 67–79. <https://doi.org/10.5937/EkoIzazov2017067M>
17. Mokhtarian, P. L. i Salomon, I. (2001.). How derived is the demand for travel? Some conceptual and measurement considerations. *Transportation Research Part A: Policy and Practice*, 35(8), 695–719. [https://doi.org/10.1016/S0965-8564\(00\)00013-6](https://doi.org/10.1016/S0965-8564(00)00013-6)
18. Penner, R. G., Perun, P. i Steuerle, C. E. (2003.). Letting Older Workers Work. *Urban Institute*.
19. Ramadhani, S. P. (2024.). The Influence of Work Life Balance and Work Experience on Employee Performance in Rocket Chicken in the City of Yogyakarta. *Malaysian Journal of Business, Economics and Management*, 52–56. <https://doi.org/10.56532/mjbem.v3i1.40>
20. Sirgy, M. J. i Lee, D.-J. (2018.). Work-Life Balance: an Integrative Review. *Applied Research in Quality of Life*, 13(1), 229–254. <https://doi.org/10.1007/s11482-017-9509-8>
21. Tao, S. i He, S. Y. (2021.). Job accessibility and joint household travel: a study of Hong Kong with a particular focus on new town residents. *Transportation*, 48(3), 1379–1407. <https://doi.org/10.1007/s11116-020-10100-4>
22. Watts, L. i Urry, J. (2008.). Moving Methods, Travelling Times. *Environment and Planning D: Society and Space*, 26(5), 860–874. <https://doi.org/10.1068/d6707>

OD NESTAŠICE DO ODRŽIVOSTI: EVOLUCIJA KONCEPTA DEMARKETINGA

MAGDALENA KUŠTELEGA

Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
magdalena.kustelega@foi.unizg.hr

IVA GREGUREC

Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2, 42000 Varaždin, Hrvatska
iva.gregurec@foi.unizg.hr

MATEA MATIĆ ŠOŠIĆ

Sveučilište u Dubrovniku
Ekonomski fakultet
Lapadska obala 7, 20000 Dubrovnik, Hrvatska
matea.matic@unidu.hr

SAŽETAK

Tradicionalno poimanje tržišta kao mjesta sjecišta ponude i potražnje se u uvjetima rastuće konkurencije značajno promijenilo. Uslijed toga, prvotni cilj diferencijacije od konkurencije u vidu provedbe marketinških aktivnosti, kojima se naglašavaju isključivo pozitivni aspekti poslovanja poduzeća, a s ciljem povećanja namjere kupnje kroz desetljeća se promijenio. Kao strateški koncept odgovornijeg načina upravljanja potražnjom, javlja se pojam demarketinga. Za razliku od klasičnog marketinga, usmjerenog na poticanje potrošnje, potražnja se provedbom demarketinga namjerno smanjuje, preusmjerava ili obeshrabruje, posebice kada je ona prekomjerna, neprofitabilna, nepoželjna, zdravstveno štetna ili nezakonita. Glavni cilj ovog rada jest prikazati evolucijski razvoj koncepta demarketinga kroz tri razdoblja - od usmjerenosti na profitabilnost poduzeća, preko društvenog demarketinga, do suvremenog poimanja demarketinga kao mehanizma uravnoteženja poslovnog rasta s ciljevima održivog razvoja i zelenog demarketinga. Rad prikazuje ključne teorijske odrednice koncepta demarketinga, poput dostatnosti, konzumacijskih koridora, cjenovne diskriminacije te usklađenosti demarketinga poruka kroz sve komunikacijske kanale. Dodatno, radom su opisane najčešće vrste demarketinga, kao i način donošenja odluka i provedbe aktivnosti kroz sva četiri elementa tradicionalnog marketinškog spleta. Teorijski dio rada potkrijepljen je praktičnim primjerima pritom ističući važnost demarketinga kao legitimnog strateškog alata, koji istodobno naglašava kako odgovornost o iznošenju istinitih i pravovremenih informacija leži na svakom pojedinom poduzeću.

KLJUČNE RIJEČI: demarketing, ponuda i potražnja, nestašica, održivost, primjeri iz prakse

1. UVOD

U suvremenom poslovnom okruženju, obilježenom rastućom sviješću o klimatskim promjenama, ograničenosti prirodnih resursa i sve zahtjevnijim očekivanjima potrošača u pogledu društveno odgovornog poslovanja, poduzeća se sve češće suočavaju sa situacijama u kojima poticanje daljnjeg rasta potražnje nije poželjno niti održivo. U takvim okolnostima demarketing se nameće kao legitiman i sve relevantniji strateški koncept poslovanja. Ovaj koncept potražnju ne promatra isključivo kao veličinu koju treba maksimizirati, već kao varijablu koju je, ovisno o kontekstu, potrebno svjesno regulirati, preusmjeriti ili privremeno, odnosno trajno smanjiti (Elgaaied-Gambier i sur., 2025). Iako je koncept prvi put definiran još 1971. godine, njegova je primjena posljednjih desetljeća značajno proširena izvan izvornog, pretežito ekonomskog okvira, obuhvaćajući područja poput zaštite okoliša, javnog zdravlja, upravljanja turističkim destinacijama i suzbijanja krivotvorina (Chaudhry i sur., 2019).

Cilj rada je analizirati razvoj koncepta demarketinga, njegove ključne oblike i instrumente primjene te na odabranim primjerima iz poslovne prakse prikazati mogućnosti i ograničenja njegove primjene. Teorijski pregled dodatno se povezuje s praktičnim primjerima poznatih demarketingških kampanja, kako bi se ilustrirala primjenjivost samog koncepta, ali i kako bi se prikazali izazovi i rizici koji prate njegovu provedbu. Stoga će se kroz teorijski i praktični dio rada prikazati evolucija koncepta demarketinga i njegovo širenje iz izvornog ekonomskog konteksta prema društvenim, okolišnim i drugim suvremenim područjima primjene. Shodno navedenom, rad je strukturiran u pet cjelina. Nakon uvoda, u prvom i drugom poglavlju prikazan je teorijski okvir koncepta demarketinga te su istaknute ključne značajke i klasifikacija samog koncepta kroz povijest. Treće poglavlje naglašava primjenu demarketingške strategije kroz sva četiri elementa marketinškog spleta posebno ističući evolucijske promjene marketinških paradigmi. Četvrto poglavlje donosi prikaz konkretnih primjera provedenih demarketingških kampanja iz različitih sektora. Na kraju je, u zaključku rada, sintetiziran prikaz svega navedenog.

2. TEORIJSKO ODREĐENJE POJMA DEMARKETING

Povijesni začeci demarketinga vežu se uz 1971. godinu i znanstveni rad pod nazivom „*Demarketing, yes, demarketing*“, kojim su autori Philip Kotler i Sidney Levy po prvi puta definirali sam pojam kao aspekt marketinga koji se bavi namjernim obeshrabrivanjem kupaca na privremenoj ili trajnoj osnovi (Chaudhry i sur., 2019; Elgaaied-Gambier i sur., 2025). Ovim radom, Kotler i Levy uveli su pojam demarketinga u marketinšku teoriju, i to kao odgovor na situacije u kojima poduzeće želi i mora smanjiti potražnju. Pritom je njihov primarni fokus stavljen na osiguravanje ekonomske učinkovitosti, imajući u vidu očuvanje ili jačanje profitabilnosti pojedinih segmenata i atraktivnosti proizvoda. A kao temeljna intelektualna inovacija koncepta javila se spoznaja da potražnju treba regulirati, a ne isključivo poticati (Chaudhry i sur., 2019; Elgaaied-Gambier i sur., 2025). Ovim konceptom ističe se jedan od osnovnih marketinških paradoksa – marketing je taj koji služi povećanju prodaje i stimuliranju potražnje, dok je demarketing taj koji, baš suprotno, prodaju i potražnju želi smanjiti, ali bez trajnog narušavanja odnosa s kupcima.

Tijekom pola stoljeća od svojeg nastanka koncept je prošao kroz nekoliko razvojnih faza. Elgaaied-Gambier i sur. (2025) tu evoluciju sustavno prikazuju kroz tri razdoblja. Sedamdesete godine dvadesetog stoljeća, obilježava naftna kriza iz 1973. godine i rastuća zabrinutost zbog nestašice, utjecaja industrijalizacije i konzumerizma. Ovo desetljeće obilježava shvaćanje

demarketinga kao strateškog pristupa usmjerenog na raspoređivanje ograničenih resursa pritom imajući u vidu dugoročnu profitabilnost poduzeća. Zatim, osamdesetih i devedesetih godina dvadesetog stoljeća, koncept demarketinga počinje se promatrati kao instrument za smanjivanje društveno nepoželjnih oblika ponašanja te se proširuje prema tzv. društvenom demarketingu. U tom kontekstu posebni fokus stavlja se na štetne učinke pušenja, alkohola i nezdrave prehrane na zdravlje potrošača, ali i na prekomjernu potrošnju prirodnih resursa i neprihvatljivo ponašanje prema okolišu. Iz tog razloga koncepta demarketinga tih godina bio je primjenjiv u brojnim sektorima poput zdravstva, turizma i ugostiteljstva, energetike i maloprodaje (Ramirez i sur., 2017). Treće razdoblje koje Elgaaied-Gambier i sur. (2025) ističu odnosi se na razdoblje od dvije tisućitih godina do danas. Ovo razdoblje obilježeno je rastućom sviješću o klimatskim promjenama, u kojem se demarketing sve više promatra kao strateški mehanizam uravnoteženja poslovnog rasta s ciljevima održivog razvoja (Elgaaied-Gambier i sur., 2025; Medway i sur., 2011). Paralelno s ovom vremenskom evolucijom, Chaudhry i suradnici (2019) ukazuju da se demarketing više ne promatra isključivo iz mikrookolišne perspektive, u odnosu na kupce, dobavljače, posrednike i konkurenciju, već se proširuje i na makrookolišne sile poput političkih, ekonomskih, sociokulturnih, tehnoloških, legislativnih i ekoloških čimbenika. Stoga se danas moderni demarketing može shvaćati kao srž održivog poslovanja koji potiče usporavanje prekomjerne potrošnje.

Ovo širenje i razvoj koncepta osobito je vidljivo u kontekstu zaštite okoliša, gdje se pojam demarketinga sve intenzivnije povezuje s idejom zelenog demarketinga (Agrawal & Mittal, 2026; Yoon i sur., 2024). Sam pojam definirali su Soule i Reich, 2015. godine opisujući zeleni demarketing kao vrstu zelenog oglašavanja čija je poruka usmjerena protiv prekomjerne potrošnje. Prema njima zeleni demarketing imao je za cilj oblikovanje ekološki prihvatljive korporativne slike i istodobno poticanje kupnje, ali uz smanjenje potrošnje na razini cjelokupne kategorije proizvoda jedne marke (Agrawal & Mittal, 2026; Wang i sur., 2024; Yoon i sur., 2024). Pojam se nadovezuje na ranije koncepte ekološki orijentiranog demarketinga koje je uveo Foxall 1995. godine s ciljem smanjenja ekološki štetnih ponašanja od strane krajnjih potrošača (Wang i sur., 2024). Azazz i suradnici (2024) zeleni demarketing opisuju kao ekstremni oblik održivosti koji kombinira poruke protiv prekomjerne potrošnje s ciljem povećanja prodaje istaknute marke, dok istodobno smanjuje ukupno korištenje proizvoda na razini kategorije radi zaštite okoliša što potvrđuje nalaze Soule i Reicha iz 2015. godine. Yoon i suradnici (2024) taj smjeru razvoja zelenog demarketinga dodatno kontekstualiziraju, ističući da se demarketing najprije pojavio kao odgovor na nestašice proizvoda i obeshrabrivanje rizičnih zdravstvenih ponašanja, da bi se potom, kroz rad Reicha i Soule, povezao s anti potrošnjom i održivim marketingom, u okviru kojih cilj nije više isključivo smanjenje potrošnje, nego poticanje održivijih obrazaca potrošnje i razmatranje alternativa tradicionalnom konzumerizmu.

Osuвременjivanje samog koncepta posebice je vidljivo kroz tranziciju pojma u digitalno okruženje. U ovom kontekstu treba istaknuti marketinške aktivnosti poduzeća kroz društvene mreže i influencerski sadržaj koji imaju utjecaj na potrošače u vidu javnog upozoravanja na potencijalno negativne strane proizvoda poznatih marki (Agrawal & Mittal, 2026). U tom smislu posebno se ističe trend deinfluencinga kojim se kroz aktivnosti influencer marketinga nastoji informirati potrošače o stvarnim prednostima proizvoda kako bi donosili odgovornije odluke i smanjili prekomjernu potrošnju (Matić Šošić & Gregurec, 2025). Nastavno na navedeno, a promatrajući suvremeni demarketing u digitalnom okruženju, treba se voditi i ostalim problemima današnjice. Onima poput potrebe za digitalnim detoksom, ograničavanjem vremena korištenja digitalnih platformi, ograničavanjem pristupa određenim digitalnim uslugama, algoritamskim upravljanjem podacima, čišćenjem baza podataka, ostavljanjem

digitalnog otiska i sl. Slijedom navedenog važnost koncepta održivog digitalnog marketinga, koji zahtjeva promjenu okoline koja donosi dugoročnu korist kako poduzeću, tako potrošaču, ali i cijelom ekosustavu je neupitna (Gregurec & Matić Šošić, 2025).

No, u konačnici, nevezano o kojoj razvojnoj fazi demarketinga se govorilo, potrebno je istaknuti kako je važno razlikovati pojam demarketinga od srodnih, ali analitički različitih konstrukata poput protumarketinga i društvenog marketinga. Protumarketing podrazumijeva potpuno odbacivanje relevantne potražnje. Dok se društveni marketing u potpunosti oslanja na standardnu upotrebu segmentacije, ciljanja, pozicioniranja i tradicionalnog marketinškog miksa radi poticanja pozitivnog ponašanja unutar cjelokupnog ekosustava (Ramirez i sur., 2017) što svakako nije isto kao koncept demarketinga koji je u fokusu ovog rada.

2.1. KLJUČNE ZNAČAJKE DEMARKETINGA

Teorijsko utemeljenje suvremenih istraživanja demarketinga oslanja se na raznolik skup koncepata i okvira, koji odražavaju interdisciplinarnost koncepta demarketinga. U kontekstu održivosti, ali i smanjenja proizvodnje i potrošnje u vidu postizanja ekološke ravnoteže (engl. *degrowth*), Elgaaied-Gambier i suradnici (2025) kao ključan koncept uvode pojam *dostatnosti* (engl. *sufficiency*). Ovaj pojam Princen je definirao kao spoznaju da, dok se neka aktivnost sve više obavlja, postoji točka „dovoljnog” trenutka i točka u kojoj je sve „previše”, odnosno kada daljnja potrošnja prestaje dodavati vrijednost ili postaje štetna (Elgaaied-Gambier i sur., 2025). Ovaj se koncept suprotstavlja načelu učinkovitosti pomičući cilj s maksimizacije outputa prema postizanju dovoljnog trenutka, kritizirajući oslanjanje na kvantitativne metrike koje zanemaruju okolišne učinke, dajući prednost zajedničkom okolišnom dobru pred privatnim interesima (Elgaaied-Gambier i sur., 2025). S ovim se konceptom povezuju i *konzumacijski koridori*, koji definiraju raspone potrošnje koji su istodobno okolišno održivi i društveno prihvatljivi (Elgaaied-Gambier i sur., 2025; Sharjeel, 2026). Provedba demarketinga aktivnosti može se promatrati i unutar šireg koncepta *makro-demarketinga*, koji predstavlja skup strategija i taktika primijenjenih na više razina sustava, osmišljenih za smanjenje ukupne ponude i potražnje radi prijelaza neodrživih marketinških sustava prema održivijim oblicima (Elgaaied-Gambier i sur., 2025; Sharjeel, 2026). Mikroekonomsku dimenziju koncepta razrađuju Kim i Shin (2016) koji demarketing smještaju unutar modela cjenovne diskriminacije drugog reda. U tom se modelu ključnim pokazuje koncept iskrivljenja kvalitete „na dnu” i koncept *suprotstavljenih poticaja*. Koncept iskrivljenja kvalitete „na dnu” (engl. *downward quality distortion*) predstavlja niz aktivnosti kojim se kvaliteta proizvoda namijenjena potrošaču niže platežne moći namjerno smanjuje kako bi se obeshrabrilo potrošača više platežne moći od lažnog predstavljanja svog preferiranog tipa kupnje (Kim & Shin, 2016; Najafi & Costa, 2026). Nadovezujući se na navedeno, koncept suprotstavljenih poticaja (engl. *countervailing incentives*) objašnjava zašto demarketing, potičući isključivo potrošača više platežne moći na transakciju, prodavatelju omogućuje djelomično ili potpuno uklanjanje te distorzije. Nadovezujući se na ovu logiku diferencijacije, autori uvode i strategiju *ekskluzivnih prodajnih kanala* (engl. *exclusive sales channel strategy*), kojom se kombinacija visoke kvalitete i cijene čini dostupnom isključivo putem kanala koji zahtijeva transakcijski napor i angažman potrošača više platežne moći (Kim & Shin, 2016; Najafi & Costa, 2026).

Koncept demarketinga usmjeren je na upravljanje potražnjom, a ne isključivo na njezino smanjenje poticanje, pri čemu se potražnja može smanjivati privremeno ili trajno, a njezin predmet može biti prekomjerna, neprofitabilna, nepoželjna, zdravstveno štetna ili nezakonita potrošnja (Chaudhry i sur., 2019; Korsun, 2025; Yuqo, 2024). Odluke o demarketingu mogu se provoditi prilagodbom bilo kojeg elementa tradicionalnog marketinškog miksa (proizvoda,

cijene, distribucije i promociju), pri čemu cilj nije nužno potpuno uklanjanje proizvoda s tržišta, nego njegovo ograničeno, odgovornije ili selektivnije korištenje (Elgaaied-Gambier i sur., 2025). Krajnji cilj veže se uz očuvanje kvalitete proizvoda ili iskustva, zaštite oskudnih resursa, očuvanja zdravlja, održavanja vrijednosti marke ili suzbijanja nezakonite ponude (Chaudhry i sur., 2019; Yoon i sur., 2024). Pritom se motivacija za provedbu marketinških aktivnosti može promatrati dvojako. Prvotno usmjerenje poduzeća veže se uz smanjenje korištenja i/ili ograničavanje pristupa resursima i objektima čija je sposobnost nošenja s potražnjom ograničena, a drugo usmjerenje na promjenu ponašanja potrošača kako bi se unaprijed smanjila potreba za tim ograničenim resursima (Medway i sur., 2011). Stoga, demarketing ima izravne implikacije za koncept tržišne orijentacije (Murad, 2024). Premda se u situacijama prekomjerne potražnje tržišna orijentacija može činiti manje relevantnom, ona ostaje nužna jer su korisnici locirani na određenom mjestu heterogeni prema različitim demografskim, bihevioralnim i psihografskim karakteristikama kao najznačajnijim varijablama segmentiranja samog tržišta (Medway i sur., 2011). Primjerice, u jeku turističke sezone, najčešće se ističe zagađenost okoliša i povećanje ugljičnog otiska koje ostavljaju brojni turisti u kratkom roku. No, istovremeno je važno promotriti njihov utjecaj na zadovoljenje prostornih kapaciteta i prosperitet lokalnog stanovništva koje svoj osobni dohodak ostvaruju u jeku ljetne ili zimske sezone (Medway i sur., 2011). U području komunikacijskih i psiholoških mehanizama obrade demarketing poruka, Yoon i suradnici (2024) koriste okvir integrirane marketinške komunikacije, koji naglašava važnost relevantnih i dosljednih poruka na različitim komunikacijskim dodirnim točkama marke, razlikujući pritom plaćene medije, putem kojih poduzeće izravno promovira svoje vrijednosti, od zasluženih medija koji obuhvaćaju ocjene i recenzije trećih strana te spominjanje same marke kroz različite digitalne kanale. Ključnim se u ovom kontekstu pokazuje koncept vjerodostojnosti društveno odgovornog poslovanja te percipiranog integriteta poduzeća, koji djeluje kao posrednički mehanizam između vjerodostojnosti i namjere kupnje (GeeksforGeeks, 2025; Yoon i sur., 2024). Wang i suradnici (2024) u kontekst zelenog demarketinga uvode koncepte specifičnosti tvrdnje u oglašavanju i uokvirivanju poruke, objašnjavajući njihovo djelovanje kroz mehanizam zaključivanja o ekološkoj brizi. Shodno navedenom, potrošači na temelju dostupnih, ograničenih informacija zaključuju je li poduzeće vođeno altruizmom (nesebičnom brigom za opću dobrobit društva) ili egoizmom (Wang i sur., 2024). U novijem, suvremenom poimanju koncepta demarketinga, Agrawal i Mittal (2026) ističu kako demarketing markiranih proizvoda na društvenim mrežama, osobito na platformi Instagram, obilježavaju specifične odrednice proizvoda i/ili marke. Influencer ili drugi korisnik objavljuje upozoravajući sadržaj o proizvodu ili marki, najčešće u obliku kratkih videozapisa (Instagram Reelsa), koji se putem pregleda, oznaka „svidi mi se”, komentara i dijeljenja brzo širi prema velikom broju korisnika, izazivajući kognitivne, emocionalne i bihevioralne reakcije pratitelja koje mogu izravno utjecati na njihove kupovne namjere, ali i na imidž same marke (Agrawal & Mittal, 2026; GeeksforGeeks, 2025). Pritom je važno kritički pristupiti svim iznesenim informacijama, budući da iste mogu biti istinite, ali mogu biti i ograničene uslijed nedostatnog znanja i/ili resursa. Zbog čega poduzeća moraju sustavno pratiti takve vrste objava i procjenjivati jesu li iznesene tvrdnje točne, djelomično točne ili ukazuju na stvaran problem (Agrawal & Mittal, 2026).

2.2. VRSTE DEMARKETINGA

Kotler i Levy izvorno su 1971. godine demarketing operacionalizirali kroz tri oblika (Chaudhry i sur., 2019; Clickadu, 2025; Medway i sur., 2011):

- Opći demarketing – kojim se smanjuje prekomjerna potražnja tijekom razdoblja nestašice, prepopularnosti ili potrebe za eliminacijom proizvoda;

- Selektivni demarketing – usmjeren na ograničavanje potražnje neprofitabilnih ili nepoželjnih tržišnih segmenata; te
- Prividni (ostenzibilni) demarketing – kojim se stvara dojam ograničene dostupnosti proizvoda radi povećanja njegove poželjnosti.

No, suvremena je literatura tu tipologiju značajno proširila i prilagodila specifičnim kontekstima primjene. Chaudhry i suradnici (2019) predstavljaju najsustavniju nadogradnju izvorne klasifikacije, uvodeći unutar općeg demarketinga dvije nove podvrste: zaštitni demarketing i preventivni demarketing.

- Zaštitni demarketing usmjeren je na ograničavanje potrošnje i smanjenje rasipanja prirodnih resursa poput vode, plina, nafte i drugih sirovina, što ga izravno povezuje s pojmom zelenog demarketinga.
- Preventivni demarketing, koji obuhvaća strategije proizvođača, kreatora politika i drugih dionika usmjeren je na smanjenje potrošnje zdravstveno štetnih proizvoda poput duhana, alkohola ili prehrambenih proizvoda slabije nutritivne vrijednosti.

Istodobno, autori selektivni demarketing proširuju uvođenjem borbenog demarketinga, koji obuhvaća taktike kojima se odvraća nepoželjna potražnja za krivotvorenim i piratskim proizvodima (Chaudhry i sur., 2019). Također, zaključeno je kako prividni demarketing u konačnici ne odgovara temeljnom cilju smanjivanja prekomjerne ili nepoželjne potražnje, budući da mu je skrivena funkcija upravo suprotna, povećanje potražnje putem stvaranja dojma oskudnosti (Chaudhry i sur., 2019; Elgaaied-Gambier i sur., 2025).

Ovu istu logiku, prema kojoj prividni demarketing gubi svoju svrhovitost unutar normativnog, održivosti usmjerenog poimanja koncepta, potvrđuju i Elgaaied-Gambier i suradnici (2025), koji u okviru potrošnje u vidu postizanja ekološke ravnoteže (engl. *degrowth* perspektive) zaključuju da bi opći demarketing trebao ovisiti o istinskoj predanosti smanjenju prekomjerne potrošnje. S druge strane, selektivni demarketing trebao bi obeshrabrivati potrošače koji već imaju dovoljno, istodobno potičući na kupnju one koji nemaju dovoljno, čime se otvara i pitanje pravedne raspodjele resursa (Elgaaied-Gambier i sur., 2025). Medway i suradnici (2011) pritom uvode dodatnu, komplementarnu podjelu na pasivni i aktivni demarketing. Pasivni demarketing implicitno je sadržan u svim fazama procesa segmentacije određenog tržišta. Ovaj oblik može biti opći, kada sama lokacija ne poprima aktivnu ulogu kojom se njezini posjetitelji potiču na akciju, ili selektivan, kada se ističu određeni atributi specifične lokacije radi ciljanja određene skupine potrošača (Medway i sur., 2011). Aktivni demarketing, s druge strane, obično se odvija tijekom diskretnog vremenskog razdoblja, često radi upravljanja krizom (Medway i sur., 2011). Kroz proučavanje radove, Kim i Shin (2016) jedini su autori koji izvornu Kotler-Levyjevu tipologiju u potpunosti napuštaju, definirajući umjesto nje tri strategije koje prodavatelj bira unutar formalnog modela cjenovne diskriminacije. Prva strategija je marketing, u kojem prodavatelj sam ulaže napor kako bi potaknuo namjeru kupnje, druga je demarketing, u kojem prodavatelj taj napor prepušta isključivo korisniku veće platežne moći, a treća je demarketing s ekskluzivnim kanalom, u kojoj je kombinacija visoke kvalitete i cijene dostupna samo putem kanala koji zahtijeva dodatni napor potencijalnog korisnika (Kim & Shin, 2016).

3. STRATEGIJA DEMARKETINGA KROZ ELEMENTE TRADICIONALNOG MARKETINŠKOG MIKSA

Praktična primjena demarketinga u analiziranoj literaturi dosljedno se prikazuje kroz prilagodbu četiriju elemenata tradicionalnog marketinškog miksa: proizvoda, cijene, distribucije i promocije. Pritom naglašavajući kako se pojedini elementi u različitim kontekstima pokazuju različito učinkovitima (Chaudhry i sur., 2019). Na razini proizvoda, demarketing se ostvaruje ili prilagodnom postojećih proizvoda ili razvojem novih proizvoda. U praksi se najčešće primjenjuje strategija prilagodbe postojećih proizvoda koju karakteriziraju smanjivanje veličine ambalaže u kojoj se sam proizvod nalazi, kao i dodavanje oznaka autentičnosti i ostalih zaštitnih elemenata na finalni proizvod koji unutar cjelokupnog procesa ne podliježe nikakvoj suštinskoj promjeni sastava (Chaudhry i sur., 2019). Primjerice prilagodba postojećih prehrambenih proizvoda vidljiva je kroz uvođenje manjih porcija ili kroz promjenu nutritivnih vrijednosti sastava proizvoda kroz smanjivanje količine šećera, masti ili alkohola (Elgaaied-Gambier i sur., 2025). Strategija razvoja novih proizvoda obuhvaća proces kreiranja potpuno novog finalnog proizvoda koji omogućuje održiviju potrošnju oskudnih resursa (Elgaaied-Gambier i sur., 2025).

Kao najizravniji i najčešće korišteni element marketinškog spleta kojim se nastoje potaknuti demarketinge aktivnosti ističe se cijena, čije povećanje ili smanjenje može rezultirati nizom popratnih aktivnosti korisnika (GeeksforGeeks, 2025; Kim & Shin, 2016). Primjerice, sve više poduzeća uvodi višerazinski sustav naplate prema obujmu potrošnje, dok se pojedina poduzeća oslanjaju na cjenovnu diferencijaciju radi očuvanja ekskluzivnosti luksuznih proizvoda. No pritom je važno napomenuti kako cijena nije uvijek primjenjiv alat, osobito kod javnih dobara kao što su primjerice nacionalni parkovi (Chaudhry i sur., 2019). Slijedom navedenoga, iako manipulacija cijenama dugoročno u najvećoj mjeri odvraća korisnika od potražnje za određenim proizvodom ili uslugom, postavlja se pitanje etičnosti korištenja takve strategije budući da se iz baze potencijalnih korisnika isključuju osobe nižeg socioekonomskog statusa (Kim & Shin, 2016; Medway i sur., 2011).

Distribucijski aspekt demarketinga obuhvaća ograničavanje pristupa, promjenu prodajnog kanala, kontrolu dostupnosti, preusmjeravanje potražnje i nadzor distribucijskih partnera (Chaudhry i sur., 2019). U slučaju kronične prepopularnosti određenog proizvoda ili usluge distribucija se može ograničiti vremenski određenim ulaskom, kvotama ili ograničavanjem broja proizvoda i usluga (Chaudhry i sur., 2019). Ukoliko je određeni proizvod potrebno prodati u što kraćem roku ili ukloniti sa samog tržišta, preostale zalihe mogu se preusmjeriti iz fizičkih poslovnica u digitalno okruženje, odnosno na web-shopove (Chaudhry i sur., 2019; GeeksforGeeks, 2025). Primjena selektivnog demarketinga pritom omogućuje da se primjerice ekskluzivni proizvodi nude samo određenoj klijenteli višeg socioekonomskog statusa putem specifičnih distribucijskih kanala i posrednika (Chaudhry i sur., 2019). Medway i suradnici (2011) identificirali su četiri konkretne strategije demarketinga mjesta, odnosno distribucije od kojih se kao najpasivnija mjera ističe potpuni izostanak marketinških aktivnosti na određenoj lokaciji za koju se nastoji smanjiti prenapučenost. Potom slijedi preusmjeravanje na alternativna mjesta (tzv. „switch marketing”) kada se u slučaju prenapučenosti određenog lokaliteta smanjuju promotivne aktivnosti vezane uz taj lokalitet, a veći naglasak potom se preusmjerava na povećanje promotivnih aktivnosti koje se odvijaju na takozvanim alternativnim lokacijama (Medway i sur., 2011). Treći strateški pristup demarketinga distribucije naziva se informacijski demarketing mjesta. Ovaj pristup predstavlja oblik aktivnog demarketinga koji provode najčešće lokalne agencije određenog mjesta, koristeći razne medije kako bi komunicirali točne i pravovremene informacije svojoj ciljnoj skupini (Medway i sur.,

2011; Najafi & Costa, 2026). Ograničenje pristupa određenoj lokaciji predstavlja posljednji mehanizam kojim se suptilno nastoji smanjiti prenapućenost određenog lokaliteta, a u kombinaciji sa različitim mehanizmima regulacije cijena nastoji se dodatno obeshrabriti korisnikova percepcije potrebe da potražuje određenu uslugu na prenapućenoj lokaciji (Chaudhry i sur., 2019; Najafi & Costa, 2026).

Promocija u demarketingu nije ograničena na oglašavanje, nego obuhvaća različite izvanmrežne i mrežne komunikacijske aktivnosti (Kaushik, 2011). One uključuju edukaciju, upozoravanje na posljedice prekomjerne potrošnje, promjenu društvenih normi, komunikaciju o oskudnosti resursa, poticanje odgovornog ponašanja i uključivanje potrošača u rješavanje problema (Chaudhry i sur., 2019; Najafi & Costa, 2026). Primjerice, u kontekstu provedbe preventivnog demarketinga, promocija može poslužiti kao alat kojim se potrošače informira o nutritivnim vrijednostima, kalorijskom unosu i odgovornoj konzumaciji prehrambenih proizvoda (Chaudhry i sur., 2019). Pritom zaštitni demarketing nastoji nizom promotivnih kampanja i poruka osvijestiti korisnike o negativnim posljedicama po organizam koje rezultiraju prekomjernom konzumacijom određenog proizvoda (Chaudhry i sur., 2019; Najafi & Costa, 2026). Krajnji cilj provedbe promotivnih aktivnosti veže se uz poticanje angažmana krajnjih potrošača koji postaju glavni akteri u vidu donošenja odluka kojima se potiče opća dobrobit cjelokupnog ekosustava (Chaudhry i sur., 2019; Najafi & Costa, 2026). Kako bi se postigao željeni efekt, sve poslane promotivne poruke moraju biti usklađene neovisno o broju i raznolikosti kanala kroz koji se distribuiraju (Kaushik, 2011; Vukasović, 2025). Stoga je i u slučaju demarketing aktivnosti koncept višekanalne komunikacije od iznimne važnosti. A dimenzija usklađenosti komunikacijskih poruka posebice je istaknuta u kontekstu društveno odgovornog poslovanja budući da neusklađene poruke mogu povećati skepticizam (Yoon i sur., 2024). Primjerice, ako se najprije prikaže demarketingški publicitet, odnosno poruka „kupujte manje“, a zatim demarketingški oglas, poruke se međusobno potvrđuju i percipiraju usklađenijima, što je povezano s većom namjerom kupnje, manjim očekivanim osjećajem krivnje i većim očekivanim zadovoljstvom proizvodom (Yoon i sur., 2024). No, ako se nakon poruke „kupujte manje“ (demarketingškog publiciteta) prikaže zeleni oglas koji potiče kupnju više proizvoda, poruke mogu djelovati neusklađeno (Yoon i sur., 2024). Suprotno tome, kada se najprije prikaže zeleni publicitet, a zatim demarketingški oglas, demarketingški se oglas može doživjeti kao napredovanje prema većoj ekološkoj predanosti (Yoon i sur., 2024). U tom slučaju prijelaz sa zelenog marketinga na demarketing ne mora narušiti odnos s potrošačima (Yoon i sur., 2024). Wang i sur. (2024) nadopunjuju postavljenu teoriju naglašavajući kako učinkovitost demarketingške poruke ovisi o skladu između specifičnosti tvrdnje i uokvirivanja poruke koje predstavlja proces selektivnog naglašavanja određenih informacija, uz izostavljanje određenih dijelova poruke s ciljem oblikovanja načina na koji će primatelj poruke istu percipirati, interpretirati i vrednovati (Vukasović, 2025; Wang i sur., 2024). Uočeno je kako specifične, činjenicama potkrijepljene tvrdnje djeluju snažnije u kombinaciji s gubitnim uokvirivanjem koje predstavlja koncept prikaza informacija kroz prizmu gubitka odnosno negativnih posljedica (Wang i sur., 2024). Pritom nejasne, apstraktnije tvrdnje bolje djeluju u kombinaciji s dobitnim uokvirivanjem kojim se korisnicima naglašavaju pozitivni ishodi, odnosno dobitci, dok ekološka relevantnost proizvoda predstavlja moderatora koji odlučuje koja kombinacija strategija je u datom trenutku za određenu ciljanu publiku najučinkovitija (Wang i sur., 2024).


4. PRIKAZ DEMARKETINGŠKIH KAMPANJA U PRAKSI

Analizirana literatura obiluje konkretnim primjerima demarketingških kampanja koji pobliže opisuju prethodno opisane teorijske i strateške odrednice koncepta. U nastavku rada bit će

predstavljani primjeri demarketinških kampanja koje se prema mišljenjima većine autora, što se može prepoznati u njihovim radovima prikupljenim istraživanjem za stolom, smatraju reprezentativnima za određenu djelatnost tercijarnog sektora. Odnosno, riječ je o kampanjama koje su ostvarile najveći odjek i medijsku pozornost na lokalnoj, ali i globalnoj razini. Jedna od poznatijih i dobro prihvaćenih demarketinških kampanja jest kampanja odjevne modne marke Patagonia „*Don't Buy This Jacket*” koja je svoj vrhunac doživjela kroz Black Friday ponudu 2011. godine (Allchin, 2013; Gelles, 2025). Naime, Patagonia je u časopisu The New York Times objavila oglas s porukom „*Ne kupujte ovu jaknu*” (engl. „*Don't Buy This Jacket*”) iznad slike svoje flis jakne (Gelles, 2025). Iako se prvotno činilo kako je riječ o spontanom i nepromišljenom marketinškom potezu (Slika 1.), ispostavilo se kako je kampanja u konačnici rezultat dugogodišnjeg razmišljanja o odgovornoj potrošnji (Allchin, 2013; Gelles, 2025). Polazište za kreiranje same kampanje proizlazi iz 1990. godine, kada je Doug Tompkins, suosnivač The North Facea i tadašnji vlasnik Esprit, globalne modne marke koja se bavi proizvodnjom odjeće, obuće i modnih dodataka, objavio sličan oglas u časopisu Utne Reader. Sama kampanja „*Don't Buy This Jacket*” sadržavala je tekst koji je objašnjavao da Black Friday, iako donosi profit trgovcima, stavlja prirodne procese i sustave „*u crveno*”, budući da ljudi svakodnevno nepotrebno troše resurse dostatne za jedan i pol planet Zemlju (Allchin, 2013; Gelles, 2025). Pritom je u vidu kreiranja demarketinške poruke korištena metoda gubitnog uokvirenja popraćena specifičnim činjenicama vezanim uz proizvodni ciklus jakne (Rawmarrow, 2024). Odnosno, naglašeno je kako je za proizvodnju jedne njihove flis jakne potrebno ukupno 135 litara vode. Pritom treba istaknuti kako emisija ugljičnog dioksida iznosi 9 kilograma, uz uvjet da je 60% korištenog materijala reciklirano (Rawmarrow, 2024). Oglas završava porukom: „*Ne kupujte ono što vam ne treba. Razmislite dvaput prije nego što kupite išta.*” (Gelles, 2025), (Allchin, 2013). Ova odvažna poruka neobičnog naslova pobudila je interes i znatiželju čitatelja oglasa, a kako je u datom trenutku njihova pažnja bila u potpunosti okupirana filozofijom Patagonije, u konačnici je poduzeće nesvjesno potaknulo angažman korisnika u vidu namjere kupnje jakne (Rawmarrow, 2024). Tako da su reakcije na oglas bile instantne, a popraćene su ne samo na lokalnoj, već i na globalnoj razini. Paradoksalno, ovaj demarketinški strateški pristup potaknuo je još veći interes za Patagonijinim asortimanom proizvoda (Gelles, 2025; Allchin, 2013). Zanimljivo je za uočiti odnos prihoda i rashoda u datom trenutku, budući da je Patagonia za objavu oglasa u časopisu The New York Times platila oko 57.000 američkih dolara, da bi u konačnici ostvarila besplatnu medijsku pozornost u protuvrijednosti od gotovo 50 milijuna američkih dolara (Gelles, 2025; Allchin, 2013). Njihova prodaja se višestruko uvećala ne samo u mjesecima, već i godinama nakon lansiranja kampanje, čime je ova demarketinška kampanja postala jedna od najuspješnijih i najhrabrijih marketinških pothvata nekog poduzeća. Spomenuti marketinški pothvat je s vremenom prerastao u zaštitni znak nove Patagonijine filozofije. Njome opisuju kako uz optimalno korištenje resursa proizvesti najbolji proizvod, pritom ne nanoseći nepotrebnu štetu ekosustavu, a istovremeno i kako inspirirati korisnika da provodi aktivnosti kojima će se nastojati minimizirati negativan učinak i nastanak nove ekološke krize (Gelles, 2025; Allchin, 2013). Kombinacija marketinga vođenog vrijednostima u vidu ostvarenja ekološke održivosti uz emocionalni apel kojim se potiče društveno odgovorno ponašanje potrošača osigurali su dugoročno ostvarenje integriteta same marke Patagonia (Rawmarrow, 2024).

industrija ne može dekarbonizirati bez smanjenja učestalosti zračnog putovanja. Pritom se dodatno pošumljavanje nikako ne može smatrati kompenzacijom utjecaja leta na cjelokupni ekosustav (Ormeshe, 2023). Kampanja je u konačnici povučena, budući da je potvrđeno kako je u proteklom razdoblju KLM doživio dosad neviđeni rast prihoda zbog povećanog, a dugoročno i neodrživog porasta zračnog prometa (Ormeshe, 2023; Sarajlić, 2022). Odvjetnički tim pritom je srušio održivi publicitet KLM-a dokazavši kako je njihova trenutna tendencija rasta kontradiktorna ostvarenju klimatskih ciljeva, to jest borbi protiv klimatskih promjena (Ormeshe, 2023; Sarajlić, 2022).

Slika 2. KLM kampanja „Fly Responsibly“



Izvor: https://marcommnews.com/wp-content/uploads/2019/07/KLM_EN_GB_OPEN-LETTER.jpg (pristupljeno 10.06.2026.)

U kontekstu prehrambene industrije Coca-Cola predstavlja primjer primjene preventivnog demarketinga usmjerenog na smanjivanje unosa kalorija (Chaudhry i sur., 2019). Poduzeće je ponudilo manje verzije standardnih pića (boce i limenke od 7,5 unci umjesto uobičajenih 12 unci), pri čemu je kampanja „Nova, savršeno mala limenka“ (engl. „New Perfectly Small Can“) manje pakiranje povezala s promišljenim uživanjem u piću, a kampanja „Osjeti taj okus“ (engl. „Taste the Feeling“) promovirala je bocu od 250 mililitara uz poruku „Malo može biti taman kako treba“ (engl. „A Little Can Be Just Right“) (Coca-colacompany, 2025; Packagingeurope, 2026). Ovaj primjer pobliže povezuje teorijske odrednice preventivnog demarketinga s konkretnim elementima marketinškog spleta. Na razini proizvoda smanjuje se količina po jedinici pakiranja, dok se na razini promocije komunicira umjerenija potrošnja, a cilj ostaje ograničenje prekomjernog kalorijskog unosa, a ne potpuno uklanjanje bezalkoholnih pića s tržišta (Chaudhry i sur., 2019). Još jedan primjer preventivnog demarketinga alkoholnog proizvoda predstavlja poznata talijanska pivovara Peroni, koja je uvela manje formate piva s nižim udjelom alkohola pod nazivom Peroncino (Chaudhry i sur., 2019; Vizard, 2016). Istodobno su provodili i edukaciju distribucijskim partnerima naglašavajući kako je trenutak u kojem se distribucijski lanac prekida onaj u kojem potencijalni kupac postaje maloljetna osoba ili osoba koja je vidno pod utjecajem opojnih sredstava (Chaudhry i sur., 2019).

Slika 3. Coca-Cola kampanja „New Perfectly Small Can”



Izvor: <https://www.adnews.com.au/campaigns/coca-cola-small-but-perfectly-formed> (pristupljeno 10.06.2026.)

Louis Vuitton je globalni luksuzni brend koji proizvodi i prodaje visokokvalitetne proizvode poput torbi, odjeće, obuće, nakita, satova i parfema, gradeći svoj uspjeh na naslijeđu, ručnoj izradi i prepoznatljivom monogramu kao simbolu statusa (Pereira, 2025). Njegova marketinška strategija temelji se na premium cijenama bez popusta, ograničenim kolekcijama i prodaji u digitalnom okruženju koje stvaraju osjećaj rijetkosti te suradnji s umjetnicima i poznatim osobama kako bi se održao osjećaj ekskluzivnosti i kulturne relevantnosti (Pereira, 2025). Stoga se samo poduzeće u literaturi pojavljuje kao primjer istodobne primjene dviju različitih vrsta demarketinga (Chaudhry i sur., 2019). Chaudhry i suradnici (2019) navode kako je poduzeće, kada je torbica Speedy postala previše raširena među mlađim potrošačkim segmentima, povećalo njezinu cijenu kako bi zaštitilo vrijednost luksuzne marke i ponovno naglasilo prestiž temeljne ponude. Tako da demarketinge aktivnosti u ovom slučaju nisu bile usmjerene na uklanjanje proizvoda, već na kontrolu njegove dostupnosti. Istodobno, poduzeće je provelo i borbeni demarketing protiv krivotvorenih torbica i novčanika, pooštavajući distribuciju originalnih proizvoda, prateći internetska tržišta te dodajući obilježja autentičnosti u komunikaciji o kvaliteti i karakteristikama originalnih proizvoda (Chaudhry i sur., 2019). Sličan koncept u vidu borbe protiv krivotvorina, vidljiv je kroz platformu eBay, koja putem programa VeRO omogućuje vlasnicima marki prijavu sumnjivih korisničkih računa, koji potom bivaju provjereni preko platforme, a u slučaju nezakonitih radnji i sankcionirani (Chaudhry i sur., 2019).

U kontekstu upravljanja destinacijama, ističe se primjer američke službe nacionalnih parkova, gdje menadžeri parkova poput Denalija i Yellowstonea razmatraju vremenski ograničen pristup, kvote posjetitelja i preusmjeravanje turista prema rubnim atrakcijama. Ovakve odluke imaju za cilj usklađivanje rekreacijske uporabe prostora s očuvanjem prirodnih resursa. Uz napomenu da cijena ostaje ograničen alat jer nacionalni parkovi ipak imaju javnu funkciju (Chaudhry i sur., 2019).

U kontekstu distribucijskih strategija demarketinga ističe se primjer kozmetičke marke Estée Lauder. Poduzeće je 2010. godine marku Prescriptives povuklo iz maloprodajne distribucije i preusmjerilo je isključivo na prodaju u digitalnom okruženju, pri čemu je, kako bi ublažilo posljedice za dugogodišnje maloprodajne partnere, trgovinama ponudilo zamjenski proizvod za oslobođeni prodajni prostor te otkupilo cjelokupne postojeće zalihe (Chaudhry i sur., 2019; Commoncog, 2026).

5. ZAKLJUČAK

Provedena analiza literature potvrđuje da je demarketing od svog nastanka 1971. godine prešao značajan evolucijski put. Iako je koncept nastao zbog potencijalnog problema nestašice resursa, ubrzo je od uskog, pretežno ekonomski motiviranog alata kojim se nastojao riješiti problem privremene neravnoteže ponude i potražnje na tržištu, evoluirao u sveobuhvatni strateški koncept. Iz tog razloga se provedba demarketinških aktivnosti danas usko povezuje s ciljevima održivog razvoja, zaštitom okoliša i društveno odgovornim poslovanjem. Prikazane teorijske odrednice pokazuju da demarketing ne teži nužno potpunom uklanjanju proizvoda ili usluge s tržišta, već njegovoj odgovornijoj, selektivnijoj ili privremeno ograničenoj potrošnji, pri čemu se odluke mogu provoditi kroz prilagodbu bilo kojeg elementa marketinškog spleta. Analizirani praktični primjeri, poput kampanje Patagonije „*Don't Buy This Jacket*“, KLM-ove kampanje „*Fly Responsibly*“, smanjenja pakiranja proizvoda poduzeća Coca-Cola i Peroni, kao i strategija diferencijacije i borbe protiv krivotvorina Louis Vuittona i eBaya, potvrđuju da poduzeća demarketing uspješno koriste kao sredstvo jačanja vrijednosti marke, integriteta i dugoročne profitabilnosti. Istodobno, primjer KLM-a upozorava na to da nedosljedna ili neutemeljena demarketinška komunikacija nosi značajan rizik od optužbi za lažno predstavljanje ekološke odgovornosti, narušavanja povjerenja potrošača i u konačnici povlačenja kampanje. Iz navedenog proizlazi da je za uspješnu provedbu demarketinga presudna usklađenost poruka na svim komunikacijskim dodirnim točkama te njihovo utemeljenje na stvarnim, provjerljivim aktivnostima poduzeća, a ne isključivo na deklarativnim izjavama. Stoga, spomenuti primjeri iz prakse, analizirani u radovima prikupljenim istraživanjem za stolom, mogu predstavljati strateške smjernice ostalim poduzećima da je moguće ostvariti profit ukoliko se interesi i opća dobrobit zajednice stave na prvo mjesto. Zaključno, može se istaknuti kako je evolucijski razvoj demarketinga kao koncepta značajno utjecao na promjenu marketinških paradigmi. Imajući u vidu promjene u poslovnom okruženju i njihovu povezanost sa smjerom marketinških aktivnosti, za očekivati je da će se demarketing kao koncept nastaviti razvijati i prilagođavati budućim promjenama u poslovanju poduzeća. Navedeno ujedno upućuje na potrebu za daljnjim i opsežnijim istraživanjem samog koncepta demarketinga te njegova utjecaja na marketinšku praksu i poslovanje poduzeća.

REFERENCE

1. Agrawal, S. R., & Mittal, D. (2026). Dealing with demarketing of branded products on social media platforms. *Marketing Intelligence & Planning*, 44(1), 43–60. <https://doi.org/10.1108/MIP-08-2024-0544>
2. Allchin, J. (2013, siječanj 23). Case study: Patagonia's 'Don't buy this jacket' campaign. *Marketing Week*. <https://www.marketingweek.com/case-study-patagonias-dont-buy-this-jacket-campaign/>
3. Azazz, A. M. S., Elshaer, I. A., Al Thani, A., Algezawy, M., Mahrous, A. A., Mansour, M. A., Moneim, A. A., & Fayyad, S. (2024). The Influence of Green Demarketing on Brand Credibility, Green Authenticity, and Greenwashing in the Food Industry. *Sustainability*, 16(21), 9215. <https://doi.org/10.3390/su16219215>
4. Chaudhry, P. E., Cesareo, L., & Pastore, A. (2019). Resolving the jeopardies of consumer demand: Revisiting demarketing concepts. *Business Horizons*, 62(5), 663–677. <https://doi.org/10.1016/j.bushor.2019.05.002>
5. Clickadu. (2025, siječanj 17). Demarketing: Strategies, Examples, and Benefits. *Clickadu-EN*. <https://www.clickadu.com/glossary/demarketing>

6. Coca-colacompany. (2025, listopad 8). *Convenient Size at the Convenience Store: Solo Coca-Cola Mini Cans Are Here*. <https://www.coca-colacompany.com/media-center/mini-can-singles-convenience-stores>
7. Commoncog. (2026). *Estée Lauder's Prescriptives: A New Luxury Brand that Died a Slow Death—Commoncog Case Library*. <https://commoncog.com/c/cases/estee-lauder-prescriptives/>
8. Elgaaied-Gambier, L., Bertrandias, L., & Bernard, Y. (2025). Degrowth plus marketing = demarketing? Rethinking demarketing as an effective tool for sufficiency. *Marketing Theory*, 25(4), 615–638. <https://doi.org/10.1177/14705931251321823>
9. GeeksforGeeks. (2025, srpanj 25). *Demarketing: Meaning, Types, Strategies and Examples*. GeeksforGeeks. <https://www.geeksforgeeks.org/marketing/demarketing-meaning-types-strategies-and-examples/>
10. Gelles, D. (2025, studeni 28). The Secret History of „Don't Buy This Jacket“ [Substack newsletter]. *David Gelles*. <https://davidgelles.substack.com/p/the-secret-history-of-dont-buy-this>
11. Gregurec, I., & Matić Šošić, M. (2025). Sustainable Digital Marketing – A New Marketing Trend. *Elektronički zbornik radova Veleučilišta u Šibeniku*, 19(1–2), 195–205. <https://doi.org/10.51650/ezrvs.19.1-2.5>
12. Kaushik, R. (2011). *Effective Communication and Marketing*. 12, 2230–7893.
13. Kim, J., & Shin, D. (2016). Price Discrimination with Demarketing. *Journal of Industrial Economics*, 64(4), 773–807. <https://doi.org/10.1111/joie.12129>
14. Korsun, O. (2025, svibanj 29). Demarketing: What kind of strategy is it? *Marketing Link LLC*. <https://marketing.link/demarketing-what-is-this-strategy/>
15. Matić Šošić, M., & Gregurec, I. (2025, veljača 28). *Suvremena-trgovina-1-2025*. *Suvremena trgovina*, vol 50., br. 1, str. 64-69. Issuu. <https://issuu.com/st-1-2015-online/docs/suvremena-trgovina-1-2025/64>
16. Medway, D., Warnaby, G., & Dharni, S. (2011). Demarketing places: Rationales and strategies. *Journal of Marketing Management*, 27(1–2), 124–142. <https://doi.org/10.1080/02672571003719096>
17. Murad, J. (2024, lipanj 29). *Demarketing: The Art of Attracting and Repelling in Marketing*. Jousef Murad. <https://www.engineered-mind.com/business/demarketing-the-art-of-attracting-and-repelling/>
18. Najafi, M., & Costa, C. (2026). Demarketing as a strategic response to overtourism: Paradoxes, pitfalls and future directions. *Journal of Hospitality and Tourism Insights*, 9(11), 1–19. <https://doi.org/10.1108/JHTI-07-2025-0808>
19. Ormeshe, E. (2023). *KLM pulls 'Fly Responsibly' ads after greenwashing lawsuit*. The Drum. <https://www.thedrum.com/news/klm-pulls-fly-responsibly-ads-after-greenwashing-lawsuit>
20. Packagingeurope. (2026, veljača 17). *Mini Coca-Cola cans target on-the-go drinking and short-term flavour runs*. Packaging Europe. <https://packagingeurope.com/news/mini-coca-cola-cans-target-on-the-go-drinking-and-short-term-flavour-runs/13930.article>
21. Pande, P. (2021, prosinac 8). *KLM Targets Responsible Flying With New Advertising Campaign*. Simple Flying. <https://simpleflying.com/klm-new-advertising-campaign/>
22. Pereira, D. (2025, rujan 14). *Louis Vuitton Marketing Strategy (2026)*. <https://businessmodelanalyst.com/louis-vuitton-marketing-strategy/>
23. Ramirez, E., Tajdini, S., & David, M. E. (2017). The Effects of Proenvironmental Demarketing on Consumer Attitudes and Actual Consumption. *Journal of Marketing Theory and Practice*, 25(3), 291–304. <https://doi.org/10.1080/10696679.2017.1311219>

24. Rawmarrow. (2024, kolovoz 6). *Ad Analysis: Patagonia's "Don't Buy This Jacket" - rawmarrowblog*. <https://blog.rawmarrow.com/ad-analysis-patagonias-dont-buy-this-jacket/08/06/2024/>
25. Sarajlić, T. (2022, prosinac 23). *Ovo su bili najveći greenwashing slučajeve 2022. Godine—Green.hr*. <https://green.hr/ovo-su-bili-najveci-greenwashing-slucajevi-2022-godine/>
26. Sharjeel. (2026, svibanj 18). Demarketing: The Surprisingly Effective Approach to Marketing. *EngageBay - All-in-One Marketing, Sales, and Service*. <https://www.engagebay.com/blog/demarketing-definition-examples/>
27. Vizard, S. (2016, svibanj 18). Peroni is a marketing-driven success story, says SABMiller. *Marketing Week*. <https://www.marketingweek.com/peroni-is-a-marketing-driven-success-story-says-sabmiller/>
28. Vukasović, T. (2025, travanj 10). *Promjene u marketingu: Budućnost ponašanja potrošača i komunikacije | DOBA Fakultet*. <https://www.doba.hr/doba-znanja/promjene-u-marketingu-buducnost-ponasanja-potrosaca-i-komunikacije>
29. Wang, J., Zhou, Y., Zhang, J., & Wang, X. (2024). Pseudo-environmentalist or true defender? How claim specificity and message framing influence consumers' brand evaluation in green demarketing ads. *Current Psychology*, 43(48), 37138–37153. <https://doi.org/10.1007/s12144-024-07117-8>
30. Yoon, H. J., Lee, Y.-J., & Sun, S. (2024). Decoding demarketing advertising effects through the IMC lens: The role of earned and paid media. *International Journal of Advertising*, 43(8), 1366–1391. <https://doi.org/10.1080/02650487.2024.2312751>
31. Yuqo, H. (2024, listopad 3). What Is Demarketing, and Should You Implement It? *Yuqo*. <https://www.yuqo.com/what-is-demarketing-and-should-you-implement-it/>



<https://crodma.hr/>