HRVATSKO DRUŠTVO
EKONOMISTA

34. TRADICIONALNO SAVJETOVANJE:

# EKONOMSKA POLITIKA HRVATSKE U 2027.

**4., 5. i 6. studenoga 2026.**
**Grand Hotel Adriatic, Opatija**

HRVATSKO DRUŠTVO
EKONOMISTA

34. TRADICIONALNO SAVJETOVANJE:

# EKONOMSKA POLITIKA HRVATSKE U 2027.

# 34. tradicionalno savjetovanje
# Ekonomska politika Hrvatske u 2027.


| | |
|---|---|
| Nakladnik: | Hrvatsko društvo ekonomista, Heinzelova 4a, Zagreb, www.hde.hr |
| Za Nakladnika: | prof. dr. sc. Darko Tipurić, predsjednik HDE-a |
| Sunakladnik: | Inženjerski biro d.o.o., Zagreb, www.ingbiro.hr |
| Za Sunakladnika: | dr. sc. Mladen Mlinarević, glavni direktor Inženjerskog biroa d.o.o. |



Znanstveno-programski odbor Savjetovanja

| | |
|---|---|
| Predsjednik: | prof. dr. sc. Darko Tipurić |
| Članovi: | nasl. izv. prof. dr. sc. Katarina Bačić |
| | prof. dr. sc. Bruno Ćorić |
| | izv. prof. dr. sc. Ana Ježovita |
| | prof. emer. dr. sc. Ljubo Jurčić |
| | prof. dr. sc. Maja Klindžić |
| | izv. prof. dr. sc. Ivana Kovač |
| | dr. sc. Željko Lovrinčević |
| | dr. sc. Mladen Mlinarević |
| | prof. dr. sc. Lucija Rogić Dumančić |
| | prof. dr. sc. Josip Tica |
| Glavne urednice: | izv. prof. dr. sc. Ana Ježovita |
| | prof. dr. sc. Lucija Rogić Dumančić |
| Urednički odbor: | izv. prof. dr. sc. Ana Ježovita |
| | izv. prof. dr. sc. Ivana Kovač |
| | prof. dr. sc. Lucija Rogić Dumančić |
| | prof. dr. sc. Josip Tica |
| | dr. sc. Ivan Jajić |
| | Elena Perić, mag. oec. |
| Lektorica: | Mirna Rudeš, prof. |
| Grafička urednica: | Ana-Marija Perić, dipl. ing. |
| Dizajn naslovnice: | Zale d.o.o. |



| | |
|---|---|
| Tisak: | Sveučilišna tiskara d.o.o., Trg Republike Hrvatske 14, 10000 Zagreb |
| Učestalost izlaženja: | jedanput godišnje |

Radovi su recenzirani na temelju dvostruke anonimne recenzije.

ISSN 1849-6482

HRVATSKO DRUŠTVO
EKONOMISTA

# EKONOMSKA POLITIKA HRVATSKE U 2027.

34. TRADICIONALNO SAVJETOVANJE

# Sadržaj

Darko Tipurić
**RIJEČ PREDSJEDNIKA** ..... 1

Vladimir Arčabić
Goran Markušić
**KONVERGENCIJA NA KREDIT? APSORPCIJSKI I KONVERGENCIJSKI KAPACITET U EU – PRIMJER HRVATSKE I PORTUGALA** ..... 9

Nenad Bakić
**INDIKATOR NEUSKLAĐENOSTI CIJENA STAMBENIH NEKRETNINA S FUNDAMENTIMA ZA HRVATSKU (HPMI-HR): KONSTRUKCIJA, DEKOMPOZICIJA I VALIDACIJA** ..... 62

Darko Horvatin
Dražen Derado
**STRUKTURNA ODRŽIVOST POSLOVNOG MODELA MIROVINSKIH OSIGURAVAJUĆIH DRUŠTAVA U REPUBLICI HRVATSKOJ** ..... 82

Dora Hercezi
Željko Bogdan
**EURO U REPUBLICI HRVATSKOJ I PERCEPCIJA NJEGOVIH UČINAKA MEĐU GRAĐANIMA** ..... 115

Ivan Madunić
**SUSTAV PRIVREMENOG UZDRŽAVANJA DJETETA U HRVATSKOJ: INSTITUCIONALNA UČINKOVITOST, FISKALNA ODRŽIVOST I RIZICI** ..... 155

Dina Dogan
Dino Ivan Dogan
**POTICANJE ULAGANJA POSLOVNIH ANĐELA U HRVATSKOJ: POREZNA ASIMETRIJA, EUROPSKA ISKUSTVA I PRIJEDLOG MJERA JAVNE POLITIKE** ..... 180

Mia Despotović
**NEUSKLAĐENOST VJEŠTINA NA HRVATSKOM TRŽIŠTU RADA: ANALIZA PREMA TIPOVIMA VJEŠTINA** ..... 198

Tado Jurić
**STRANI RADNICI IZ AZIJSKIH ZEMALJA U REPUBLICI HRVATSKOJ: DIGITALNO-DEMOGRAFSKA ANALIZA MIGRACIJSKIH I INTEGRACIJSKIH OBRAZACA** ..... 223

Tomislav Baković
**TEHNOLOŠKE REVOLUCIJE I UMJETNA INTELIGENCIJA: EKONOMIKA IZGRADNJE PODATKOVNIH CENTARA** ..... 250

Ivan Jajić
**PROCESNA PRIMJENA UMJETNE INTELIGENCIJE U PODUZEĆIMA: USPOREDBA HRVATSKE I EUROPSKE UNIJE PREMA VELIČINI PODUZEĆA** ..... 269

Mia Despotović
Stella Antolović
Rosa Stojnić
**IZLOŽENOST POSLOVNIH I EKONOMSKIH ZANIMANJA GENERATIVNOJ UMJETNOJ INTELIGENCIJI: ANALIZA NA RAZINI RADNIH ZADATAKA S OSVRTOM NA HRVATSKO TRŽIŠTE RADA** ..... 288

Ivana Kovač
Patricija Adanić
**STRUKTURNE ZNAČAJKE, PREPREKE I RAZVOJNE PERSPEKTIVE ŽENA PODUZETNICA U HRVATSKOJ: REZULTATI EMPIRIJSKOG ISTRAŽIVANJA** ..... 310

Karolina Kokot
Marina Klačmer Čalopa
**AGENCIJSKI TROŠKOVI: IDENTIFICIRANJE TROŠKOVA KOJI NISU U POTPUNOSTI ISKAZANI U FINANCIJSKIM IZVJEŠTAJIMA** ..... 334

Dino Ivan Dogan
Dina Dogan
**SMJENA GENERACIJA KAO NEPREPOZNATI OKIDAČ RESTRUKTURIRANJA: PRIMJENA OKVIRA SEDAM KLJUČNIH ELEMENATA (7P) NA PRIJENOS POSLOVANJA U HRVATSKIM OBITELJSKIM PODUZEĆIMA** ..... 350

Elena Perić
Domagoj Hruška
**O ČEMU RASPRAVLJAMO? SUPSTITUCIJA PROSUDBE, PARADIGMA ODNOSA I NADZORNI KAPACITET KAO TRI SREDIŠNJE OSI RASPRAVE O ODNOSU ODBORA I UMJETNE INTELIGENCIJE** ..... 369

Nikolina Dreven
Lorena Pikl
Ivan Malbašić
**SVRHOVITA ORGANIZACIJA: SPOJ STRATEGIJE, VODSTVA I OSOBNE SVRHE ZAPOSLENIKA** ..... 391

Marko Mikšić
**UPRAVLJAČKA ODGOVORNOST U TRGOVAČKIM DRUŠTVIMA U VLASNIŠTVU JEDINICA LOKALNE SAMOUPRAVE U REPUBLICI HRVATSKOJ: ANALIZA PRIMJENOM PRILAGOĐENOG RELOF INDEKSA** ..... 410

Ana Andabaka
Jakov Grković
**DIGITALNE PUTOVNICE ZA PROIZVODE** ..... 427

Ivana Unukić
Rita-Krin Boduljak
Danijela Ciberlin
Aleksandar Erceg
**MEĐUOVISNOST INDUSTRIJSKE SIMBIOZE I ZELENOG PODUZETNIŠTVA – PRIMJER HRVATSKE** ..... 452

Umihana Umihanić Bukvić
Lana Cindrić
**IMPLEMENTACIJA KRUŽNIH POSLOVNIH MODELA U HRVATSKIM INDUSTRIJSKIM PODUZEĆIMA: ULOGA INOVATIVNOSTI I VLADINE POTPORE** ..... 471

Sanel Volarić
**DIGITALNA TRANSFORMACIJA I DIGITALNA ZRELOST: KONCEPTUALNE RAZLIKE I NJIHOV MEĐUSOBNI ODNOS** ..... 488

# RIJEČ PREDSJEDNIKA

Hrvatska se danas nalazi na kraju jednoga i na početku drugoga puta: između dovršenih integracija, koje su tri desetljeća davale smjer njezinim reformama, i razdoblja u kojem će taj smjer prvi put morati odrediti sama. Nakon Europske unije, europodručja i schengenskoga prostora, OECD je posljednja velika postaja; iza nje više nema kluba kojemu bi tek trebalo pristupiti ni vanjskoga ispita koji bi zamijenio vlastitu prosudbu. Time se mijenja i narav pitanja koje si moramo postaviti. Na prošlogodišnjem smo savjetovanju upozorili da Hrvatska sustavno zaostaje u produktivnosti; ove godine valja pitati – zašto. Odgovor vodi, među ostalim, prema nedovoljno dobrim institucijama, prema njihovoj sposobnosti da pravila pretvore u praksu, a praksu u novu vrijednost.

Nema dvojbe da je članstvo snažna potvrda dosegnutoga i da Hrvatskoj može donijeti dugoročne koristi, od veće investicijske privlačnosti i regulatorne predvidivosti do sudjelovanja u oblikovanju pravila prema kojima posluju najrazvijenija gospodarstva. Na dan pristupanja slušat ćemo govore o povijesnom uspjehu i dovršenom integracijskom putu, i ti će govori imati svoje opravdanje. Kada se, međutim, ugase svjetla ceremonije i odlože protokolarne fotografije u arhive, ostat će pitanje važnije od samoga formalnog čina: ulazi li Hrvatska u OECD kao država koja je visoke međunarodne standarde pretvorila u vlastitu institucionalnu praksu ili kao država koja je uskladila propise, ali ne i način na koji njezine institucije zbilja djeluju?

Samo članstvo danas više nije predmet ozbiljnijih prijepora. Mnogo je neizvjesnije hoće li OECD doista ući u Hrvatsku, odnosno hoće li preuzeta mjerila doprijeti do povjerenstava za imenovanja, nadzornih odbora i uprava državnih poduzeća, dakle ondje gdje se uistinu odlučuje o položajima, utjecaju i javnom novcu. Ulog pritom nije samo upravljački nego i razvojni, jer o kakvoći institucija ovisi i sposobnost gospodarstva da iz istih resursa stvara više. Ako se ta mjerila zaustave na pragu institucija, OECD će u Hrvatskoj ostati poput gosta kojega su svečano dočekali, ali ga nikada nisu pustili dalje od predvorja.

Pristupni će proces utvrditi da su zakoni usklađeni, strategije donesene i procedure uspostavljene. Ne može, međutim, sam po sebi jamčiti da su pravila postala učinkovita granica političkoj diskreciji, da su profesionalni kriteriji nadjačali političku podobnost niti da odgovornost ima cijenu. Domet članstva ovisit će zato o tome koja će od dviju suprotstavljenih logika upravljanja prevladati u hrvatskim institucijama. Prema meritokratskoj logici javna vlast znači dužnost, položaj odgovornost, a napredovanje rezultat znanja i rada. Nasuprot njoj stoji morokratska logika, obrazac negativne selekcije koji smo u lanjskom Zborniku opisali kao poredak u kojem ovisnost, lojalnost i pripadnost mrežama moći postaju važnija mjerila uspona od stručne samostalnosti, integriteta i učinka. Sustav tada ne bira najboljega, nego bespogovornog poslušnoga i najpouzdanijega iz perspektive onih koji kontroliraju imenovanja. Ne postavlja se onoga tko će najviše učiniti, nego onoga tko će najmanje pitati.

Nigdje se taj prijepor ne vidi jasnije nego u poduzećima u državnom vlasništvu. Uz klasičan agencijski problem razdvojenog vlasništva i upravljanja ondje se pojavljuje dulji i politički obojen lanac odgovornosti: građani su krajnji vlasnici, politički akteri u njihovo ime izvršavaju vlasnička prava, nadzorni odbori trebaju kontrolirati uprave, a uprave raspolažu velikim ekonomskim resursima. Posrednik između građana i poduzeća svoju legitimnost ne stječe poslovnim rezultatom, nego izbornim mandatom, pa

upravama može nametati ciljeve koji odstupaju od stvaranja dugoročne vrijednosti. Meka proračunska ograničenja pritom neutraliziraju tržišnu disciplinu, a trošak neuspjeha prebacuju na porezne obveznike i buduća razdoblja.

Taj se fenomen može nazvati *političkom kolonizacijom*. Dok pojam zarobljavanja države opisuje privatne aktere koji izvana nastoje javne institucije podvrgnuti vlastitoj koristi, kod političke kolonizacije smjer je obrnut, jer politički centar moći iznutra podvrgava javne organizacije i gospodarske resurse vlastitim interesima. Čini to politiziranim imenovanjima, instrumentalizacijom poslovnog odlučivanja i neutralizacijom nadzora koji formalno postoji, ali ostaje bez učinka. Krajnji je ishod privatizacija javnog interesa: koristi se koncentriraju unutar povlaštenog kruga, a troškovi i rizici prenose na poduzeće, državu i građane.

OECD je u Ekonomskom pregledu Hrvatske iz 2023. godine upozorio na veliku ekonomsku težinu državnog portfelja, čija je imovina prema tadašnjim procjenama odgovarala približno polovici godišnjeg BDP-a, te na nadzorne odbore koji nisu raspolagali potrebnom neovisnošću ni punom odgovornošću za donošenje odluka iz svoje nadležnosti. Pregled iz 2026. godine bilježi važan napredak u zakonodavnom okviru, ali ih i dalje zadržava među područjima u kojima su potrebni pomaci, osobito u ograničavanju neprimjerenoga političkog utjecaja. Budući da ta poduzeća imaju ključnu ulogu u energetici, prometu, komunalnim djelatnostima i mrežnoj infrastrukturi, njihova neučinkovitost nije izoliran problem javnih financija, nego skriveni porez na cijelo gospodarstvo *sui generis*. Cijena energije, prijevoza i komunalnih usluga ulazi u troškove svakoga poduzeća, pa se loše upravljanje državnim portfeljem prelijeva u nižu produktivnost privatnoga sektora koji s njime nema nikakve vlasničke veze.

Ništa od toga nije nova spoznaja. Hrvatska znanost i stručna javnost desetljećima, i na našem savjetovanju, upozoravaju na politička imenovanja, nejasne ciljeve državnog vlasništva i raspršenu odgovornost. Trebalo je,

slikovito rečeno, da se domaća dijagnoza vrati s pečatom iz Pariza kako bi postala dovoljno ozbiljna za zakone, strategije i rokove. Taj paradoks govori manje o OECD-u, a više o našoj institucionalnoj kulturi i njezinoj sklonosti da reformama prizna veću težinu kada postanu dio međunarodno praćenoga procesa nego kada proizlaze iz vlastitoga stručnog znanja.

Reformski je odgovor, treba priznati, dobar i temeljit. Zakon o pravnim osobama u vlasništvu Republike Hrvatske, na snazi od 1. listopada 2025. godine, zahtijeva postojanje svrhe odnosno opravdanje za državno vlasništvo i razmatranje izlaska kada ono prestane postojati. Vlasnička politika i Uredba o izboru i imenovanju članova nadzornih i upravnih organa, donesene 30. srpnja 2026. godine, uvode javni natječaj prema unaprijed utvrđenim kriterijima kompetentnosti, a Zakon propisuje da najmanje 33 posto članova nadzornog odbora mora biti neovisno. Neostvarivanje mjerljivih ciljeva može postati osnova za opoziv uprave, dok Pravilnik o objavljivanju i izvještavanju zahtijeva javnu, lako pretraživu i strojno čitljivu objavu podataka o ciljevima, rezultatima, rizicima i primitcima. Na papiru je riječ o velikom institucionalnom iskoraku.

No tu počinje najteži dio reforme. Nova pravila trebaju provesti upravo oni akteri čiju diskrecijsku moć ona ograničavaju, a morokratski poredak ima znatan kapacitet da promjene neutralizira. Otpor ne mora biti otvoren; učinkovitije je prihvatiti pravilo, a zatim kontrolirati njegovo tumačenje, provedbu i sankcije. Javni natječaj tako može postati ritual s unaprijed poželjnim ishodom, kriteriji stručnosti dovoljno široki da obuhvate i one čiju su selekciju trebali spriječiti, a nadzorni odbori mogu održavati sastanke i uredno voditi zapisnike, a da na ključne odluke gotovo ne utječu.

Takva se pojava naziva *izomorfnom mimikrijom*: preuzimaju se obilježja institucija koje se smatraju uspješnima, ali ne i sposobnosti potrebne za ostvarivanje njihove svrhe, pa se mijenja način na koji institucija izgleda, a ne ono što može učiniti. Formalna se struktura odvaja od stvarnoga organizacijskog djelovanja, a provjera, kada zamijeni prosudbu i

odgovornost, rađa vlastite obrede. Broj sjednica nadzornog odbora lako je dokazati, njegovu neovisnost mnogo teže.

Iskustvo srednje i istočne Europe to potvrđuje: sve su nove članice preuzele istu pravnu stečevinu i prošle iste pregovaračke postupke, a njihovi se razvojni ishodi znatno razlikuju, jer isto pravilo ne daje isti učinak kada ga provode uprave različite sposobnosti. Ako je politička kolonizacija proces prisvajanja javne institucije, institucionalna mimikrija postaje način njezine legitimacije.

Tako nastaju *fasadne institucije*, koje mogu biti opasnije od otvoreno slabih: vidljiva slabost stvara pritisak da se nešto promijeni, a fasada ga prikriva. Stvarna i fasadna institucija mogu imati ista pravila, organizacijske sheme i uredne dokumente. Razlika postaje vidljiva tek kada pravilo dođe u sukob s interesom nekog moćnog aktera. Stvarna institucija tada ograničava moć; fasadna joj se prilagođava.

Potpuna depolitizacija državnih poduzeća nije ni realistična ni u cijelosti poželjna, jer demokratski izabrana vlast mora odlučiti zašto država neko poduzeće posjeduje i što od njega očekuje. Ograničiti treba prijelaz legitimne političke odgovornosti za vlasničku svrhu u političku kontrolu nad nadzorom i poslovnim odlučivanjem. Realističniji je reformski cilj zato *funkcionalna depolitizacija*: politika određuje svrhu vlasništva i strateške ciljeve, nadzorni odbori biraju se prema profesionalnim kriterijima i obavljaju djelotvoran nadzor, uprave vode poslovanje bez neformalnih uplitanja izvana, a uspjeh i neuspjeh proizvode posljedice.

Polazište je jasna svrha vlasništva za svako veće poduzeće, kakvu primjerice oblikuje norveški model razlikovanjem poduzeća s komercijalnim ciljem od onih čija je svrha ostvarivanje javne politike, jer bez nje nije moguće razlikovati poslovni neuspjeh od opravdanoga troška javne zadaće. Jednako su potrebni nadzorni odbori koji nisu transmisijski mehanizam političke volje, nego institucionalni filtar između vlasnika i uprave. Zakonska

konzultacija s Vladom pri izboru uprave može biti legitimna, ali ne smije prerasti u instrukciju; od odbora nije moguće tražiti odgovornost za izbor koji je nastao izvan njega.

Odgovornost uprave pritom mora biti stvarna, ali ne i proizvoljna. Cilj koji nema posljedicu nije upravljački cilj, nego informacija, dok smjena zbog „lošeg rezultata" ne smije postati izgovor za uklanjanje politički nepoželjne uprave. Transparentnost mora omogućiti kontrolu, a ne samo objavu, jer revizijska preporuka koja se godinama ponavlja bez promjene ponašanja prestaje biti korektiv i postaje zapis o nemoći sustava. Naposljetku, državno vlasništvo ne smije stvarati pretpostavku da je kapital besplatan, a nadzorni odbor mora moći zaustaviti investiciju čija se poslovna logika ne može obraniti, čak i kada uživa snažnu potporu vlasti.

Državna poduzeća najvidljivije su, ali ne i jedino mjesto na kojem se odlučuje o dometu članstva. Isti raskorak, u kojem forma napreduje brže od sposobnosti, objašnjava i zašto hrvatska ukupna faktorska produktivnost, onaj dio rasta koji ne dolazi od više rada i kapitala, nego od tehnologije, organizacije i kvalitete institucija, raste sporije i nestabilnije nego u usporedivim zemljama. Pripadnost prestižnome klubu može podići dohodak; sposobnost da se on održi i uveća vlastitom učinkovitošću ne dolazi s članskom iskaznicom.

Hrvatski pokazatelji otkrivaju gdje ta sposobnost nedostaje. Proizvodnost po satu rada danas je na gotovo istom udjelu europskog prosjeka, oko dvije trećine, na kojem je bila u godini ulaska u Uniju. U znanje i istraživanje ulažemo znatno manje nego Unija u cjelini, u izvozu prevladava ono što drugi rade jeftinije, a industrija napreduje sporije nego u zemljama s kojima smo zajedno krenuli. Plaće, uz to, rastu brže od onoga što rad stvara. Rast plaća nije problem, nego cilj razvoja; problem nastaje kada ga produktivnost trajno ne prati, jer se ta razlika prije ili poslije naplaćuje konkurentnošću, zaposlenošću ili inflacijom.

Iz te dijagnoze proizlaze nužnosti koje ne ovise o tome tko obnaša vlast. Razvoj se mora odmaknuti od rentijerskoga modela, koji počiva na sezoni, nekretninama i niskim maržama, i usmjeriti prema djelatnostima visoke dodane vrijednosti. Ulaganje u znanje i tehnologiju mora prestati biti proračunski ostatak, a ljudski kapital postati glavna razvojna investicija društva kojemu se radno sposobno stanovništvo smanjuje. Uprava, pravosuđe i poduzeća moraju se digitalizirati, poduzetništvo rasteretiti, a kapital usmjeriti prema proizvodnji i inovacijama umjesto prema potrošnji. Plaće dugoročno valja usklađivati s rastom produktivnosti, što nije poziv na suzdržavanje u zahtjevima rada, nego na vođenje politike koja produktivnost povećava.

Ništa od toga nije ostvarivo samo propisom. Institucija djeluje tek kada se istodobno ispune tri uvjeta: kvalitetno pravilo, povjerenje koje mu daje sadržaj i ljudi koji znaju i smiju provesti ono što je propisano. OECD može pridonijeti prvome. Drugi i treći mogu izgraditi samo domaće institucije vlastitom praksom, a upravo njih morokratska selekcija najprije razara. Društvo koje poslušnost nagrađuje više nego rezultat ne može očekivati da će mu zakon o inovacijama donijeti inovacije. Reforme svedene na formu proizvode knjižnice zakona koji se ne primjenjuju; tek kada pravilo, povjerenje i sposobnost napreduju zajedno, institucija počinje stvarati vrijednost.

Razdoblje nakon pristupanja važnije je od procesa koji mu prethodi. Dok je članstvo jasan politički cilj, reforme se ubrzavaju i usklađuju; nakon njegova ostvarenja nova pravila moraju pronaći vlastito uporište u domaćim institucijama. Najpostojaniji oblik neuspjeha nije otvoreni otpor reformi, nego njezino formalno prihvaćanje uz očuvanje postojećih odnosa utjecaja.

Valja izbjeći dvije suprotne zablude. *Institucionalni voluntarizam* vjeruje da će dobro napisana pravila sama preobraziti duboko ukorijenjene odnose moći, *a institucionalni fatalizam* da se ništa ne može postići dok se prethodno ne promijeni politička kultura. Formalna se pravila doista mijenjaju brže od

neformalnih ograničenja, no institucije i obrasci ponašanja međusobno se oblikuju, pa ono što je u početku iznimka dosljednom primjenom s vremenom može postati uobičajena norma.

OECD između mogućih ishoda ne može izabrati umjesto Hrvatske. Može ponuditi standarde, usporedbe i međunarodnu provjeru te povećati cijenu odstupanja od dogovorenih pravila. Ne može, međutim, stvoriti političku volju za ograničavanjem vlastite moći niti osigurati profesionalni integritet onih koji tu moć svakodnevno izvršavaju. Članstvo će biti priznanje hrvatskoga institucionalnog napretka, ali njegov će puni smisao ovisiti o tome hoće li se usvojena pravila primjenjivati i onda kada njihov ishod nije politički poželjan.

Svaka zemlja, u konačnici, ima onakav razvoj kakav joj omogućuju njezine institucije. U tome nema fatalizma, jer svaka generacija ima institucije kakve gradi vlastitim svakodnevnim odlukama: koga imenuje, što nagrađuje, što prešućuje i na što više ne pristaje. Tu odgovornost nije moguće prenijeti ni na povijest, ni na okolnosti, ni na Pariz.

Radovi okupljeni u ovom Zborniku, svaki iz vlastite perspektive, pridonose toj raspravi o odnosu između ekonomske politike, institucija koje je provode i produktivnosti o kojoj ovisi životni standard hrvatskih građana. Hrvatsko društvo ekonomista i ovim izdanjem ostaje vjerno uvjerenju da stručna rasprava ima najveću vrijednost kada prethodi odlukama, a ne kada ih naknadno komentira.

Prof. dr. sc. Darko Tipurić

predsjednik Hrvatskog društva ekonomista

JEL klasifikacija: O47, O52, O43, F15, E22

Izvorni znanstveni rad

# KONVERGENCIJA NA KREDIT? APSORPCIJSKI I KONVERGENCIJSKI KAPACITET U EU – PRIMJER HRVATSKE I PORTUGALA[1]

Vladimir Arčabić*

Goran Markušić**

## SAŽETAK

U radu se analizira postoji li konvergencija među zemljama EU te, važnije, kakav je sastav rasta koji vodi do konvergencije. Teza rada je da brzina konvergencije sama po sebi ne govori je li konvergencija dugoročno održiva, jer gospodarski rast može biti rezultat akumulacije rada i kapitala ili rasta produktivnosti. U radu predlažemo razlikovanje apsorpcijskog kapaciteta, mjerenog zbrojem doprinosa rada i kapitala rastu, od konvergencijskog kapaciteta, mjerenog zbrojem doprinosa ljudskog kapitala i ukupne faktorske produktivnosti. Procjenjuje se model uvjetne konvergencije za 27 članica EU u razdoblju od 2000. do 2025. te se provodi računovodstvo rasta za Hrvatsku i Portugal na temelju triju baza podataka: Penn World Table 11.0, EU KLEMS

* Izv. prof. dr. sc. Vladimir Arčabić, Sveučilište u Zagrebu, Ekonomski fakultet, Hrvatska akademija znanosti i umjetnosti i Institut za razvoj i međunarodne odnose (e-mail: varcabic@efzg.hr), korespondirajući autor.

** Dr. sc. Goran Markušić, Sveučilište u Zagrebu, Ekonomski fakultet (e-mail:gmarkusic@net.efzg.hr).

[1] Ovaj je članak financiran sredstvima Europske unije NextGenerationEU u okviru Poziva IIP 581 2025.

i AMECO. Rezultati potvrđuju uvjetnu konvergenciju, pri čemu su sredstva iz europskih fondova usko povezana s njezinom brzinom, a institucije određuju njezinu gornju granicu. Nismo pronašli dokaze o postojanju konvergencijskog zida pri pragu od 80 % prosjeka BDP-a po stanovniku, ali su doprinosi ljudskog kapitala i produktivnosti statistički značajni samo iznad tog praga. Portugal je proveo fazu infuzije, ali nije napravio prijelaz u fazu inovacije te pokazuje karakteristike zemlje u zamci srednjeg dohotka. Hrvatski konvergencijski kapacitet blizu je prosjeka EU, ali ispod razine usporedivih novih članica, uz iznimno snažnu epizodu između 2021. i 2023., dok od 2024. prevladava akumulacija rada i fizičkog kapitala. Povezanost isplata iz europskih fondova i produktivnosti nije statistički značajna, premda Hrvatska pokazuje blago pozitivnu vezu, za razliku od Portugala, gdje je veza blago negativna. Iz toga slijedi da sama stopa iskorištenosti sredstava iz EU fondova nije dostatna mjera uspješnosti kohezijske politike, već ju je potrebno nadopuniti podacima o konvergencijskom kapacitetu.

**Ključne riječi:** konvergencija, kohezijska politika, razvojna zamka, računovodstvo rasta, ukupna faktorska produktivnost, apsorpcijski i konvergencijski kapacitet, Hrvatska, Portugal.

## 1. UVOD

Proračun Europske unije u tekućem višegodišnjem financijskom okviru, zajedno s fondom za oporavak od pandemije bolesti COVID-19, iznosi dva bilijuna eura, a najveći je dio tih sredstava namijenjen koheziji među regijama i zemljama članicama. Hrvatsko gospodarstvo nakon pandemije raste iznimno dinamično i ubrzano sustiže razvijenije članice EU. Postavlja se pitanje je li taj rast dugoročno održiv ili se radi o „konvergenciji na kredit“ koju dominantno pokreće priljev sredstava iz europskih fondova. Odgovor određuje i ocjenu uspješnosti kohezijske politike i izglede Hrvatske da nastavi konvergirati nakon završetka Mehanizma za oporavak i otpornost 2026. godine.

Središnja je ideja rada da brzina konvergencije ne govori o sastavu rasta koji dovodi do konvergencije. Ista stopa konvergencije može biti rezultat akumulacije fizičkog kapitala financiranog sredstvima EU ili rasta produktivnosti, a ta dva načina imaju bitno različite posljedice za održivost. Tu razliku u radu operacionaliziramo razlikovanjem apsorpcijskog i konvergencijskog kapaciteta. Apsorpcijski kapacitet je sposobnost

gospodarstva da raspoloživa sredstva pretvori u rad i fizički kapital te se mjeri zbrojem njihovih doprinosa rastu. Konvergencijski kapacitet je sposobnost da se inputi pretoče u trajan rast produktivnosti, i mjeri se zbrojem doprinosa ljudskog kapitala i ukupne faktorske produktivnosti. Apsorpcijski kapacitet osigurava rast dok traje priljev EU sredstava, dok konvergencijski kapacitet osigurava rast koji preživljava njihov prestanak. Zamka srednjeg dohotka (ili razvojna zamka) mogu se u tom okviru definirati kao stanje visokog apsorpcijskog i niskog konvergencijskog kapaciteta.

Takvo razlikovanje izravno se preslikava na strategiju 3i Svjetske banke – investicije, infuzija, inovacija (Svjetska banka, 2024), prema kojoj se prikladan model rasta mijenja kako zemlja postaje razvijenija. Zemlje niskog dohotka rastu kroz investicije, odnosno akumulaciju fizičkog kapitala i izgradnju osnovne infrastrukture. Na srednjim razinama dohotka investicije nisu dovoljne te ih je potrebno upariti s infuzijom, dakle s usvajanjem postojećih tehnologija i s izgradnjom ljudskog kapitala. Na višim razinama dohotka presudne postaju inovacije, odnosno pomicanje tehnološke granice, što se očituje u rastu ukupne faktorske produktivnosti. Mjerni instrument kojim se taj okvir može provjeriti jest računovodstvo rasta (Solow, 1957; Jorgenson i Griliches, 1967), koje rast dekomponira na doprinose faktora proizvodnje i na rezidual. Doprinos fizičkog kapitala odgovara investicijama, doprinos ljudskog kapitala zajedno s doprinosom informacijsko-komunikacijskog i nematerijalnog kapitala odgovara infuziji, a doprinos ukupne faktorske produktivnosti odgovara inovaciji.

Analiza se provodi na dvije razine. Prvo, na razini svih 27 članica procjenjuje se model uvjetne konvergencije za razdoblje od 2000. do 2025. godine, uz ispitivanje uloge sredstava iz europskih fondova i kvalitete institucija. Drugo, na razini pojedinih zemalja provodi se računovodstvo rasta, također za svih 27 članica, s detaljnim prikazom za Hrvatsku i Portugal. Portugal je odabran kao usporedna zemlja jer je nakon razdoblja uspješnog rasta pao ispod 80 % prosjeka BDP-a per capita Europske unije i tamo se zadržao, što ga čini standardnim primjerom zemlje u razvojnoj zamci unutar EU. Računovodstvo rasta provodi se usporedno na tri baze podataka jer nijedna sama ne pokriva sve što je potrebno. Penn World Table 11.0 (Feenstra, Inklaar i Timmer, 2015) daje najdulju seriju te usluge kapitala i indeks ljudskog kapitala. EU KLEMS, izdanje 2023. (Bontadini i sur., 2023), jedini razdvaja kapital na informacijsko-komunikacijski, ostali materijalni i nematerijalni, čime omogućuje punu podjelu na tri komponente strategije 3i, ali za Hrvatsku ta podjela postoji tek od 2009. AMECO, proljetna verzija 2026. (Europska

komisija, 2026), jedini pokriva razdoblje provedbe Mehanizma za oporavak i otpornost i seže do 2027.[2]

Rad ima tri doprinosa. Prvo, strategiju 3i Svjetske banke, koja je u izvornom obliku deskriptivni okvir, operacionalizira kao mjerljivu dekompoziciju rasta i time je čini provjerljivom na podacima. Drugo, dekompoziciju provodi usporedno na tri baze podataka uz dokumentirano usklađivanje definicija, čime razdvaja nalaze koji su robusni na izbor izvora od onih koji nisu. Treće, povezuje pitanje konvergencije na agregatnoj razini EU s pitanjem sastava rasta na razini pojedine zemlje, vezu koju literatura o kohezijskoj politici i literatura o zamci srednjeg dohotka rijetko uspostavljaju izravno.

Glavni nalazi mogu se sažeti kako slijedi. U Europskoj uniji postoji uvjetna konvergencija, a sredstva iz europskih fondova i kvaliteta institucija usko su povezani s njezinom brzinom. Sredstva iz fondova mogu kratkoročno supstituirati kvalitetu institucija, ali institucije određuju gornju granicu konvergencije i time njezinu održivost. Agregatne dokaze o postojanju konvergencijskog „zida" na razini od 80 % prosjeka BDP-a per capita Europske unije nismo pronašli: konvergencija je statistički značajna, a njezina procijenjena brzina statistički je jednaka ispod i iznad tog praga. Izostanak zida, međutim, ne znači i izostanak zamke. Ljudski kapital i ukupna faktorska produktivnost statistički su značajni samo u poduzorku zemalja iznad 80 % prosjeka, dok ispod tog praga značajne ostaju samo investicije, što je obrazac u skladu s tvrdnjom da se pokretači rasta mijenjaju s razvojnim statusom i što motivira prelazak s brzine na sastav rasta.

Računovodstvo rasta pokazuje da Portugal ima obilježja zemlje u razvojnoj zamci. Doprinos ukupne faktorske produktivnosti rastu u razdoblju od 1996. do 2023. godine iznosi minus 0,25 postotnih bodova godišnje, dok je doprinos ljudskog kapitala s 0,51 postotnim bodom drugi najveći u EU. Portugal stoga nije zapeo u fazi investicija, već na prijelazu iz infuzije u inovaciju. Hrvatski je konvergencijski kapacitet u prosjeku viši, 1,01 postotni bod godišnje, ali je to unutar prosjeka novih zemalja članica i ispod vrijednosti baltičkih zemalja, Slovačke i Poljske. Iznimno snažna konvergencijska epizoda zabilježena je između 2021. i 2023. godine. Od 2024. godine sastav hrvatskog rasta mijenja se u nepovoljnom smjeru, jer počinju dominirati doprinosi rada i fizičkog kapitala, a konvergencijska košarica prema projekcijama za 2026. i 2027.

[2] Realizirani podaci pokrivaju razdoblje do 2025., a podaci za 2026. i 2027. godinu predstavljaju projekciju.

pada na nulu. Povezanost isplata iz europskih fondova i ukupne faktorske produktivnosti nije statistički značajna ni u jednoj od dviju zemalja, premda je nagib blago pozitivan za Hrvatsku i blago negativan za Portugal, što razlikuje zemlje međusobno.

Rad je organiziran na sljedeći način. Nakon uvodnog poglavlja, drugo poglavlje se bavi pitanjem konvergencije i kohezijske politike na agregatnoj razini svih zemalja članica EU. U poglavlju se detaljnije problematizira pitanje „konvergencije na kredit" kao i uloge kvalitete institucija i sredstava iz EU fondova na proces konvergencije. U trećem poglavlju se detaljnije analizira problem zamke srednjeg dohotka i razlike između apsorpcijskog i konvergencijskog kapaciteta zemalja. U četvrtom poglavlju fokus analize se prebacuje na Hrvatsku i Portugal te se provodi detaljno računovodstvo rasta na primjeru odabrane dvije zemlje, ali se rezultati uspoređuju i na razini svih 27 zemalja članica. Naposljetku, neformalnom analizom grafikona rasipanja utvrđuje se povezanost između ukupne faktorske produktivnosti i sredstava iz EU fondova. Poglavlje 5 donosi glavne zaključke.

# 2. KONVERGENCIJA I KOHEZIJSKA POLITIKA

## 2.1. Proširenje EU i potreba za snažnijom kohezijom

S vremenom, Europska unija širila se na Mediteran te na istočnu i jugoistočnu Europu. Proširenja su u pravilu obuhvaćala slabije razvijene zemlje, što je stvorilo potrebu za jačom kohezijom i smanjenjem razlika.

Povijesni razvoj europskih integracija ukazuje na dinamiku širenja Europske unije na nove zemlje i dublju integraciju postojećih. Pojačana integracija ogleda se u regulatornom smislu uvođenjem Jedinstvenog europskog akta koji je stupio na snagu 1987. godine. Akt je propisao obvezu međusobnog priznavanja, gdje bi proizvodnja robe u jednoj članici automatski omogućila njezinu cirkulaciju u svim drugim. Ovo je načelo uklonilo potrebu za dugotrajnim pregovorima o specifikacijama svakoga pojedinog proizvoda i dovelo do bržeg usklađivanja različitih regulativa. Osim toga, Akt je uveo glasovanje kvalificiranom većinom, što je otežalo mogućnost da jedna zemlja blokira odluke. Uvođenje stvarnoga jedinstvenog tržišta predviđenoga Rimskim ugovorima predviđeno je do 1992. godine. Donošenjem Sporazuma iz Maastrichta, kojim je Europska unija osnovana, predviđeno je uvođenje

zajedničke valute čime bi se dodatno pojačala integracija među zemljama članicama.

Osim regulatornih izmjena, a potaknuto mediteranskim proširenjem u osamdesetim godinama, EU je stavila veći naglasak na regionalnu politiku. Tada i nastaje skupni naziv europskih strukturnih fondova, među kojima je Europski fond za regionalni razvoj najizdašniji. Strukturnim fondovima namijenjeni su veći iznosi i reformiran je način dodjele potpora kroz stvaranje višegodišnjih potpora, odnosno programsko financiranje i bolju koordinaciju među fondovima (Croxford, Wise i Chalkley, 1987). Nakon sklapanja Sporazuma u Maastrichtu, Unija je stvorila novi Kohezijski fond namijenjen financiranju programa u zemljama članicama čiji je bruto nacionalni dohodak ispod 90 % prosjeka EU. Cilj je bio olakšati provođenje politika predviđenih Sporazumom.

U očekivanju značajnoga istočnog proširenja, EU ponovno provodi reforme svojega unutarnjeg funkcioniranja sklapanjem Sporazuma u Amsterdamu i Nici. Sporazumima se uredio način funkcioniranja Europskog parlamenta i Vijeća. Istočnim proširenjem nove članice bi dovele do povećanja broja stanovnika za 28 %, ali BDP-a tek za 5 %, što je ukazivalo na značajne razlike u razvijenosti (Nahuis i de Mooji, 2001). Zbog toga je 1997. godine Europska komisija donijela Agendu 2000. Postavljena su tri cilja regionalne politike u financijskom razdoblju 2000. – 2006. (financiranje regija čiji BDP je manji od 75 % prosjeka EU, pomoć regijama koje trebaju gospodarsko restrukturiranje i financiranje obrazovnih programa i programa zapošljavanja).

Financijska perspektiva 2007. – 2013. obilježena je Globalnom financijskom krizom. Posljedica na funkcioniranje regionalne politike je reorijentacija od dugoročnog financiranja strukturnih nedostataka prema ublažavanju posljedica recesije. U financijskoj perspektivi 2014. – 2020., Europska komisija stavlja veći naglasak na rješavanje problema niske konkurentnosti EU uz istodobno suočavanje s klimatskim izazovima. Kasprzyk i Wojnar (2021) i Becker, W. i sur. (2020) ocjenjuju da je u Uniji došlo do napretka u postizanju svih ciljeva, ali postoje značajne razlike među članicama. Najbolji uspjeh imale su zemlje sjeverne Europe uz pojedine istočnoeuropske zemlje, dok su najgori rezultat imale mediteranske zemlje. U navedenim programskim razdobljima dolazi do reformi u načinu funkcioniranja regionalne politike gdje europski strukturni fondovi služe ne samo povećanju kohezije među članicama već i provođenju zajedničkih politika. Isto se nastavilo u financijskoj perspektivi 2021. – 2027., kada je dodatno uveden

program *Next Generation EU* kao odgovor na COVID krizu. U posljednje tri financijske perspektive strukturnim fondovima bilo je namijenjeno 347 milijardi eura (za razdoblje 2007. – 2013.), 404 milijarde eura (za razdoblje 2014. – 2020.) i 368 milijardi eura (za razdoblje 2021. – 2027.) kako bi se smanjile regionalne razlike među članicama i provodile zajedničke politike.

S obzirom na iznose posvećene koheziji, ali i sve dubljoj političkoj i ekonomskoj integraciji EU koja je prikazana kroz ovaj kratak pregled, postavlja se pitanje postižu li zemlje članice željene razine razvoja.

## 2.2. Održiva konvergencija ili konvergencija na kredit

Ako zemlje s nižom razinom dohotka per capita imaju veće stope gospodarskog rasta od zemalja s višim dohocima, dolazi do postupnog sustizanja ili konvergencije dohodaka. Teorijski temelj konvergencije je neoklasični model gospodarskog rasta (Solow, 1956; Swan, 1956) gdje je stopa rasta dohotka funkcija inicijalne razine dohotka i ostalih determinanti poput stope štednje, stope amortizacije, tehnološkog napretka, kvalitete institucija i sl. Mankiw i sur. (1992) i Durlauf i sur. (2005) ističu da ako je procijenjeni koeficijent uz inicijalnu razinu dohotka negativan, govorimo o uvjetnoj konvergenciji. Konvergencija je uvjetna jer se kontroliraju ostale karakteristike među zemljama. Apsolutna konvergencija dohodaka je situacija u kojoj postoji konvergencija među dohocima bez kontroliranja za ostale faktore rasta te se ona najčešće javlja u slučaju homogenih skupina.

Jedan od ciljeva kohezijske politike Europske unije je smanjenje razlika u dohocima među zemljama članicama i poticanje razvoja slabije razvijenih zemalja. Drugim riječima, pojam kohezije možemo izjednačiti s pojmom konvergencije dohodaka. Teorijski model konvergencije nam omogućuje ocjenu uspješnosti kohezijske politike EU.

**Slika 1. Kretanje BDP-a per capita zemalja EU u razdoblju od 2000. do 2025.**

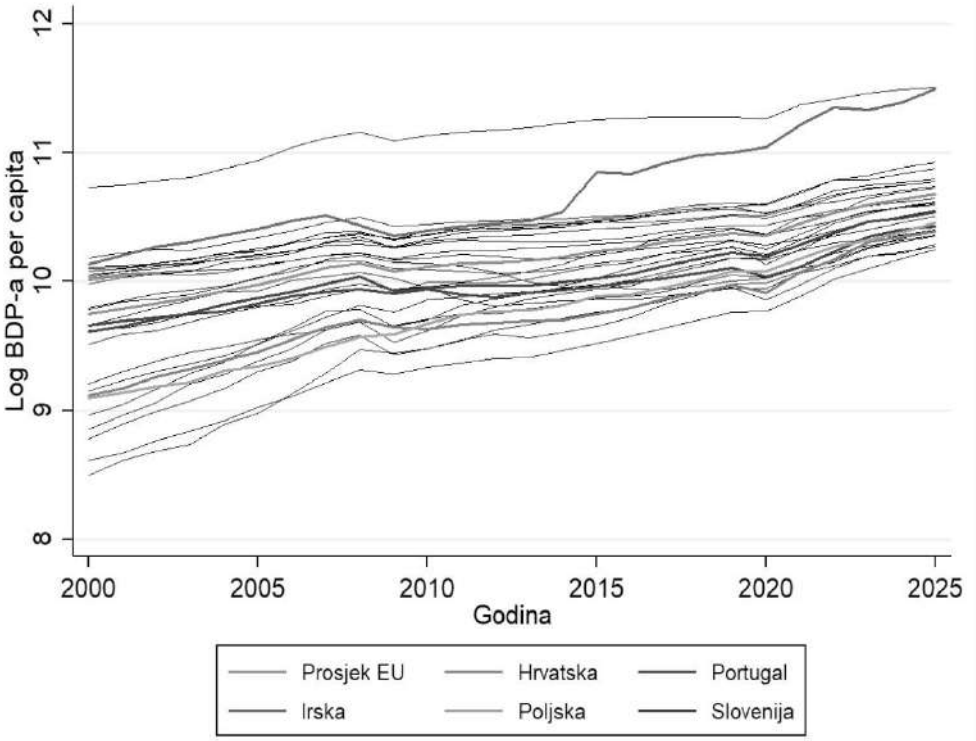


Izvor podataka: ARDECO baza.

Na Slici 1. prikazano je kretanje BDP-a per capita (prema paritetu kupovnog standarda) za razdoblje 2000. – 2025. Vidljivo je da su sve zemlje članice ostvarile značajan napredak u porastu dohotka u promatranom razdoblju. Prosječni BDP per capita u EU porastao je za oko 150 % sa 17.000 EUR na 43.000 EUR. U Hrvatskoj je u promatranom razdoblju porastao za oko 250 % (s 9.100 na 32.500 EUR), nešto manje nego u Irskoj i Poljskoj (oko 290 %), ali više nego u Sloveniji (150 %) ili Portugalu (115 %). Ako se promatraju inicijalne razine BDP-a per capita koje su za Hrvatsku i Poljsku bile niže nego za Sloveniju i Portugal, veći rast u promatranom razdoblju podupire ideju konvergencije dohodaka. Formalnije, ako se na grafikonu promatra raspršenost u 2000. godini i 2025. godini, vidljivo je da se ona relativno

smanjila, što dodatno upućuje na postojanje konvergencije, a time i na uspješnost kohezije u EU.[3]

**Slika 2. Relativni BDP per capita zemalja EU u razdoblju od 2000. do 2025.**

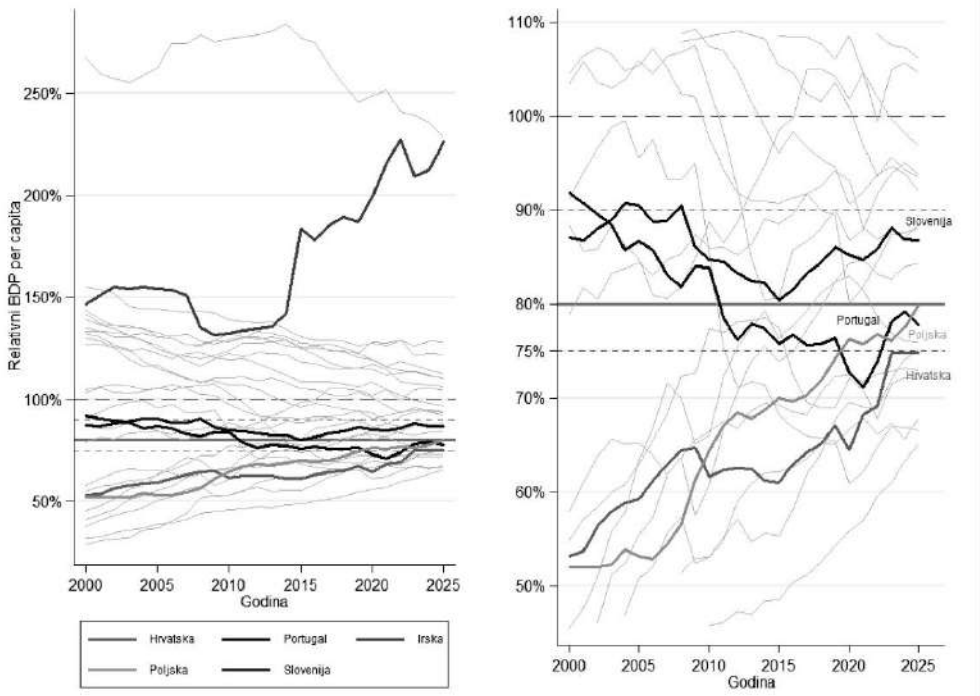


Izvor podataka: ARDECO baza.

## *Konvergencijski zid ili konvergencija na kredit*

Druga perspektiva se pojavljuje ako se promatra relativni BDP per capita, odnosno BDP per capita u odnosu na EU prosjek. Na Slici 2. prikazana su dva panela koji prikazuju relativni udio BDP-a per capita u prosjeku EU. Prvi panel prikazuje cijeli raspon relativnih udjela za zemlje članice EU u razdoblju od 2000. do 2025. godine. BDP per capita Luksemburga značajno je iznad prosjeka EU u cijelom promatranom razdoblju, ali s tendencijom

[3] Doista, koeficijent varijacije u 2000. godini iznosi 5,88, dok u 2025. godini iznosi 2,95, što je gotovo upola manje.

pada. S druge strane, Irska je značajno povećala svoj BDP per capita relativno u odnosu na EU prosjek, djelomično i zbog promjene obuhvata nacionalnih računa. Ako promatramo cijeli skup zemalja, vidljivo je da je raspršenost oko prosjeka bila veća u 2000. i smanjuje se do 2025. godine, što ponovno ide u prilog tezi o postojanju konvergencije unutar EU. Pritom se relativni udio BDP-a per capita zemalja koje su bile iznadprosječne u 2000. godini postupno smanjuje, a ispodprosječnih zemalja povećava. Isto ide u prilog konvergencijskom modelu gdje bogatije zemlje imaju niže stope rasta od siromašnijih, stoga se i njihov relativni udio smanjuje.

Međutim, drugi fenomen koji se uočava je problematika „zida" u rasponu od 75 do 90 % prosjeka EU. Zid se javlja kada slabije razvijene zemlje intenzivno koriste sredstva iz EU fondova za rast temeljen na akumulaciji rada i kapitala. Zemlje dosegnu razinu BDP-a per capita od 80 % prosjeka Europske unije, ali tu zapnu u svojevrsnu zamku jer rast baziran na akumulaciji nije održiv. Kada intenzivan priljev sredstava iz fondova završi, konvergencija stane, pa se zbog toga može kolokvijalno govoriti o „konvergenciji na kredit". Takav slijed događaja predstavlja zamku srednjeg dohotka ili regionalnu razvojnu zamku o kojoj se detaljnije govori u idućem poglavlju.

Na desnom panelu Slike 2. istaknute su tri horizontalne linije koje predstavljaju 75 %, 80 % i 90 % prosjeka EU. Također su istaknuti relativni udjeli Slovenije, Portugala, Poljske i Hrvatske. Relativni udio Portugala, dugogodišnje članice EU, se u promatranom razdoblju smanjio s preko 90 % na ispod 80 % relativnog udjela u prosjeku EU. Slovenija, koja je prije Globalne financijske krize uspjela dostići 90 % prosjeka EU, nakon pada do razine 80% nije se uspjela vratiti na prethodnu razinu. Poljska i Hrvatska su u ovom razdoblju pokazale značajan napredak, počevši od razine oko 50 % prosjeka do oko 75 % u slučaju Hrvatske, odnosno 80% u slučaju Poljske. Hrvatska u posljednjih nekoliko godina pokazuje izrazito dinamičan rast te znakove stagnacije u najrecentnijem razdoblju, što sugerira potencijalno dostizanje „zida" poput Portugala i Slovenije. Poljska pak i dalje uspijeva ostvariti napredak te je u 2025. dostigla 80 % prosjeka EU.

Navedene zemlje su značajne korisnice sredstava iz europskih strukturnih fondova. Štoviše, zemlje ispod 75 % prosjeka smatraju se slabije razvijenima i imaju mogućnost većih potpora. Nakon prijelaza te granice, zemlje ispod 90 % bruto nacionalnog dohotka imaju mogućnost korištenja sredstava iz Kohezijskog fonda.

Postojanje „zida“ na razini od oko 80 % prosjeka EU treba, međutim, uzeti s oprezom jer ga je empirijski teško nedvojbeno potvrditi. Prvi je razlog priroda same mjere: relativni BDP per capita mjeri se u odnosu na prosjek EU, pa stagnacija relativnog udjela može biti posljedica brzine rasta ostalih članica, promjena sastava EU uslijed proširenja ili statističkih specifičnosti pojedinih zemalja (primjerice, slučaj Irske), a ne nužno prestanka rasta zemlje koja se promatra. Drugi je razlog nestabilnost procijenjenih pragova. Eichengreen, Park i Shin (2012) empirijski identificiraju dohodovne razine na kojima brzorastuća gospodarstva naglo usporavaju, ali već u revidiranoj analizi (Eichengreen, Park i Shin, 2014) pokazuju da se ti pragovi mijenjaju s uzorkom, razdobljem i specifikacijom te da usporavanje može nastupiti u više različitih dohodovnih raspona. Im i Rosenblatt (2015) u pregledu literature pokazuju da nalazi o zamci srednjeg dohotka presudno ovise o tome definira li se dohodak apsolutno ili relativno te koja se metoda klasifikacije koristi, zbog čega dokazi o posebnoj koncentraciji stagnacije upravo na srednjim razinama dohotka nisu robusni.

Treći je razlog statističke prirode. Pritchett i Summers (2014) upozoravaju da je velik dio zabilježenih usporavanja rasta zapravo regresija prema srednjoj vrijednosti, odnosno očekivana posljedica toga da se iznadprosječno visoke stope rasta ne održavaju trajno, a ne dokaz o strukturnoj zamci vezanoj uz određenu razinu dohotka. Uz to, broj zemalja koje su se u promatranom razdoblju uopće približile granici od 80 % prosjeka EU malen je, serije su kratke i prekinute strukturnim lomovima poput globalne financijske krize, dužničke krize i pandemije, pa je snaga bilo kojeg testa pragova ograničena. Naposljetku, literatura o konvergencijskim klubovima (Durlauf i Johnson, 1995; Durlauf, Johnson i Temple, 2005) upućuje na to da se umjesto jednoga univerzalnog praga vjerojatnije radi o više ravnotežnih stanja, pri čemu pripadnost pojedinom klubu ovisi o ljudskom kapitalu, kvaliteti institucija i strukturi gospodarstva. Upravo je zato koncept razvojne zamke u novijoj literaturi operacionaliziran višestrukim mjerilima, odnosno usporedbom regije s vlastitom prošlošću te s nacionalnim i europskim prosjekom (Diemer i sur., 2022), umjesto jednom graničnom vrijednošću. Zid na 80 % stoga treba shvatiti kao deskriptivnu pravilnost i istraživačku hipotezu koju podupiru i službeni podaci o zaustavljanju konvergencije dijela članica (Europska komisija, 2024), a ne kao empirijski čvrsto utvrđen prag.

Dodatan razlog zbog kojeg se zid na 80 % teško uočava u podacima proizlazi iz nalaza Cerque i Pellegrinija (2023). Autori izravno ispituju što se događa s regijama koje izgube status konvergencijske regije i time dožive pad priljeva

sredstava iz kohezijske politike. Rezultati pokazuju da u prosjeku ne postoji oštar prekid rasta u trenutku prelaska praga prihvatljivosti (tj. „zid"), nego dugoročno pozitivan učinak sredstava koji traje dulje od samih priljeva. Autori pritom naglašavaju da je učinak izrazito heterogen i ovisan o obilježjima regije i lokalnom gospodarskom kontekstu, kao i o fazi ciklusa u kojoj do smanjenja sredstava dolazi. Upravo ta heterogenost i osjetljivost na makroekonomski kontekst dodatno otežavaju identifikaciju praga: ako se stagnacija javlja samo kod dijela zemalja i samo u nepovoljnim uvjetima, prosječni će učinak biti statistički neznačajan iako pojedinačne putanje, poput portugalske, upućuju na zaustavljanje konvergencije.

Zaključno, teško je donijeti precizne zaključke o zidu pri razini od 80 % prosjeka BDP-a per capita EU ili konvergenciji na kredit. Premda neke zemlje, poput Portugala, pokazuju takve karakteristike, fenomen nije dovoljno proširen da bi se mogao generalizirati.

## *Održivost konvergencije*

Kako bi se ispitala održivost konvergencije, primjenjuje se panel analiza iz rada Markušić (2026), a zaključak je da konvergencija postoji, usko je vezana uz isplate iz EU fondova i kvalitetu institucija te se okvirno može reći da pokazuje znakove održivosti.

Formalna procjena modela uvjetne konvergencije za 27 zemalja članica EU u razdoblju od 2000. do 2025. godine prikazana je u Tablici 1. Procjenjuje se model uvjetne beta konvergencije sa stopom gospodarskog rasta kao zavisnom varijablom i sljedećim nezavisnim varijablama: inicijalna razina BDP-a per capita (definirana kao pet vremenskih pomaka unatrag i izraženo u paritetu kupovnog standarda), investicije (izraženo u paritetu kupovnog standarda), stopa rasta stanovništva, ljudski kapital mjeren kao udio stanovništva s tercijarnim obrazovanjem, ukupna faktorska produktivnost (TFP), stopa zaposlenosti i Indeks ekonomskih sloboda kao mjera institucionalne kvalitete.

Osim stope gospodarskog rasta i stope rasta stanovništva, sve ostale varijable su logaritmirane. Podaci se odnose na 27 zemalja članica EU u razdoblju od 2000. do 2025. godine. Podaci su preuzeti iz baze ARDECO (BDP per capita u PPS, prosječan godišnji broj stanovnika na temelju kojega je izračunata stopa rasta stanovništva, stopa zaposlenosti, investicije u milijunima EUR PPS) i Penn World Table (ljudski kapital i ukupna faktorska produktivnost) i baze podataka Fraserovog instituta (Indeks ekonomskih sloboda).

Procjenjuju se tri modela panel modelom s fiksnim efektima, čime se kontroliraju individualni i vremenski fiksni efekti. Modeli se međusobno razlikuju prema obuhvatu zemalja. Prvi model uključuje sve zemlje, drugi model uključuje zemlje koje imaju BDP per capita manji od 80 % prosjeka EU, dok treći model uključuje preostale zemlje koje imaju BDP per capita veći ili jednak 80 % prosjeka EU. Rezultati su prikazani u Tablici 1.

Rezultati analize sva tri modela upućuju na postojanje uvjetne konvergencije među zemljama EU u promatranom razdoblju jer je koeficijent uz inicijalnu razinu BDP-a per capita statistički značajan i negativan. Rezultati su potvrdili intuiciju Slike 1. da su se razlike među članicama u pogledu BDP-a per capita u promatranom razdoblju smanjile.

**Tablica 1. Uvjetna konvergencija u EU-27 od 2000. do 2025.**

| | (1) Puni uzorak | (2) BDP p.c. < 80 % | (3) BDP p.c. ≥ 80 % |
|---|---|---|---|
| VARIJABLE | Stopa gospodarskog rasta | Stopa gospodarskog rasta | Stopa gospodarskog rasta |
| Inicijalna razina BDP-a per capita | -0.114*** | -0.108*** | -0.153*** |
| | (0.0176) | (0.0322) | (0.0249) |
| Investicije | 0.0408*** | 0.0701*** | 0.0309** |
| | (0.00721) | (0.0222) | (0.0132) |
| Stopa rasta stanovništva | -1.304*** | -1.828** | -1.101*** |
| | (0.339) | (0.708) | (0.361) |
| Ljudski kapital | 0.253*** | 0.168 | 0.287*** |
| | (0.0854) | (0.112) | (0.0930) |
| TFP | 0.128** | 0.0420 | 0.268** |
| | (0.0523) | (0.0346) | (0.0994) |
| Stopa zaposlenosti | 0.0249 | -0.0768 | 0.0334 |
| | (0.0440) | (0.0946) | (0.0536) |
| Indeks ekonomskih sloboda | -0.0410 | -0.0379 | -0.170** |
| | (0.0318) | (0.0853) | (0.0729) |
| Constant | -0.0361 | -0.332 | 1.069 |
| | (0.284) | (0.551) | (0.754) |
| Broj promatranja | 648 | 234 | 414 |
| R-kvadrat | 0.635 | 0.701 | 0.659 |
| Broj zemalja | 27 | 12 | 20 |
| FE – zemlje | Da | Da | Da |
| FE – godine | Da | Da | Da |

Napomena: Robusne standardne pogreške u zagradama. *** p < 0.01, ** p < 0.05, * p < 0.1.
Izvor: Autori.

Pojednostavnjen način provjere postojanja „zida“ u konvergenciji pri razini od 80 % prosjeka BDP-a per capita EU analizira se s modelima (2) i (3) u Tablici 1. Naime, zadnja dva modela procjenjuju se na poduzorku promatranja gdje je BDP per capita ispod 80 % prosjeka EU (Model 2) odnosno iznad 80 % prosjeka (Model 3). Zbog definicije praga od 80 % prosjeka BDP-a per capita EU, neke zemlje s vremenom prelaze iz jedne skupine u drugu. Naime, u prvom se poduzorku nalaze samo promatranja koja su niža od 80 % prosjeka BDP-a per capita EU, a u drugom su poduzorku ostala promatranja. Zemlja koja je prije nekog razdoblja bila ispod praga od 80 %, a nakon tog razdoblja je iznad praga naći će se u oba poduzorka.

U oba modela postoji konvergencija jer su koeficijenti uz inicijalnu razinu BDP-a per capita negativni. U Modelu 3 je koeficijent apsolutno veći (negativniji), što bi načelno sugeriralo bržu konvergenciju (−0,153 nasuprot −0,108). Međutim, testiranje značajnosti razlike između tih dvaju koeficijenata Waldovim testom pokazuje da razlika nije statistički značajna[4], pa se na temelju toga ne može potvrditi postojanje „zida“ u konvergenciji.

Predznaci procijenjenih koeficijenata u Tablici 1. u skladu su s očekivanjima teorijskog modela rasta, osim koeficijenta uz Indeks ekonomskih sloboda koji nije statistički signifikantan u punom uzorku. Investicije imaju pozitivan i statistički značajan utjecaj na stopu rasta u sva tri modela, stopa rasta stanovništva negativan i značajan, a ljudski kapital i TFP pozitivan utjecaj. Stopa zaposlenosti nije statistički značajna ni u jednoj specifikaciji. Suprotno od očekivanja, indeks ekonomskih sloboda negativan je i statistički značajan jedino u modelu procijenjenom na uzorku zemalja iznad 80 % prosjeka EU.

Najzanimljiviji nalaz proizlazi iz usporedbe poduzoraka. Ljudski kapital i TFP statistički su značajni u punom uzorku i u uzorku zemalja iznad 80 % prosjeka EU, ali ne i u uzorku zemalja ispod te razine, gdje su njihovi koeficijenti znatno manji i neznačajni. Istodobno je koeficijent uz investicije upravo u tom poduzorku najveći. To sugerira da zemlje na nižim razinama razvijenosti rastu prvenstveno na temelju akumulacije kapitala i investicija, a ne na temelju ljudskog kapitala i rasta ukupne faktorske produktivnosti, koji postaju relevantni tek na višim razinama dohotka. Taj je nalaz u skladu s logikom strategije 3i, o kojoj će više riječi biti u nastavku rada (točka 3.4), prema kojoj investicijska faza rasta u jednom trenutku mora biti zamijenjena

[4] Nulta hipoteza Waldovog testa o jednakosti koeficijenata ne može se odbiti uz F-statistiku od 0,29 i p-vrijednost 0,597.

fazama usvajanja tehnologije i inovacija koje počivaju upravo na ljudskom kapitalu i produktivnosti.

## 2.3. Strukturni fondovi, kvaliteta institucija i konvergencija

### *Pregled literature*

Empirijska literatura o uspješnosti kohezijske politike potvrđuje da strukturni fondovi imaju pozitivan, ali uvjetovan i nejednako raspoređen utjecaj na gospodarski rast. Serija radova Beckera, Eggera i von Ehrlicha, koja se koristi granicom prihvatljivosti od 75 % prosjeka EU kao izvorom kvazieksperimentalne varijacije, pokazuje da transferi u okviru Cilja 1 povećavaju stope rasta regija primatelja, ali bez učinka na investicije i zaposlenost (Becker, Egger i von Ehrlich, 2010). Autori nadalje utvrđuju da su prinosi na potpore opadajući te da postoji razina intenziteta transfera iznad koje dodatna sredstva više ne doprinose rastu, pri čemu je značajan dio regija primatelja financiran iznad te razine (Becker, Egger i von Ehrlich, 2012). Ključan je nalaz da učinkovitost sredstava presudno ovisi o apsorpcijskom kapacitetu regije kojega definiraju razinom ljudskog kapitala i kvalitete institucija, pa znatan dio regija ne raspolaže uvjetima potrebnima da transfere pretvori u rast (Becker, Egger i von Ehrlich, 2013). Osim toga, procijenjeni učinci pokazuju izraženu tranzitornost jer se rast usporava ili prestaje nakon prekida priljeva sredstava (Becker, Egger i von Ehrlich, 2018).

Pellegrini i sur. (2013) primjenom regresije diskontinuiteta na regije oko granice od 75 % također nalaze statistički značajan i ekonomski relevantan pozitivan učinak Cilja 1 na rast BDP-a per capita, čime potvrđuju da politika u prosjeku ostvaruje svoj konvergencijski cilj. Crescenzi i Giua (2020) pak pokazuju da taj prosječni učinak može zavarati. Naime, učinci kohezijske politike izrazito su heterogeni među zemljama članicama i snažno posredovani nacionalnim institucionalnim i političkim kontekstom, tako da se pozitivni učinci na rast i zaposlenost koncentriraju u dijelu zemalja, dok u drugima nisu statistički značajni. Zajednički zaključak te literature jest da sredstva iz strukturnih fondova nisu sama po sebi dovoljna za trajno sustizanje, već njihov doprinos ovisi o kvaliteti institucija, ljudskom kapitalu i intenzitetu potpore, što je upravo pretpostavka na kojoj se temelji analiza koja slijedi.

## *Analiza utjecaja strukturnih fondova na konvergenciju*

U nedavnom istraživanju Markušića (2026) proučavan je utjecaj kvalitete institucija i izdataka iz europskih strukturnih fondova na konvergenciju BDP-a per capita NUTS 2 regija Europske unije. Iz tog se pristupa može izvući zaključak ne samo o značajnosti kvalitete institucija za proces konvergencije već i o komplementarnosti između kvalitete institucija i izdataka iz strukturnih fondova.

## *Podaci*

Istraživanje obuhvaća 214 NUTS 2 regija u razdoblju od 2002. do 2018. godine. U istraživanju su korištene sljedeće varijable: stopa rasta BDP-a per capita regija, inicijalna razina BDP-a per capita regije (definirana kao razina BDP-a per capita pomaknuta pet razdoblja unatrag), udio investicija u BDP-u, stopa rasta stanovništva, stopa zaposlenosti, udio ukupnog iznosa plaćanja iz EU fondova u BDP-u (ukupna plaćanja odnose se na zbroj izdataka iz fondova ERDF, ESF, CF, EAFRD, EMFF, FEAD i YEI) iz četiri programska razdoblja (1994. – 1999., 2000. – 2006., 2007. – 2013. i 2014. – 2020.), ljudski kapital, ukupna faktorska produktivnost i Indeks ekonomskih sloboda. Podaci su preuzeti iz baze ARDECO, Penn World Table (ljudski kapital i ukupna faktorska produktivnost) i baze podataka Fraserova instituta (Indeks ekonomskih sloboda).

## *Metode*

Procjenjuje se sljedeći model s trostrukim interakcijskim članom:

$$\begin{aligned} g_{i,t} &= \alpha_i + \rho_t + \beta_1 y_{i,t-\tau} + \beta_2 F_{it} + \beta_3 Q_{i,t} + \\ &+\lambda_1 y_{i,t-\tau} F_{it} + \lambda_2 y_{i,t-\tau} Q_{it} + \lambda_3 F_{it} Q_{it} + \\ &+\theta y_{i,t-\tau} F_{i,t} Q_{i,t} \\ &+\mu X_{it} + \varepsilon_{it} \end{aligned} \tag{1}$$

gdje su $g_{i,t}$ stopa rasta BDP-a per capita, $y_{i,t-\tau}$ je inicijalna razina BDP-a per capita ($\tau = 5$), $F_{i,t}$ su ukupni izdaci iz EU fondova kao udio u BDP-u regije, $Q_{i,t}$ je Indeks ekonomskih sloboda, $y_{i,t-\tau} * F_{i,t} * Q_{i,t}$ je interakcijski član i $X_{it}$ je vektor ostalih kontrolnih varijabli. $\alpha_i$ i $\rho_t$ su individualni i vremenski fiksni efekti. Model omogućuje istodobno promatranje postoji li konvergencija i koje varijable utječu na konvergenciju. Trostruki interakcijski član pokazuje utjecaj institucionalnog konteksta na uspješnost korištenja sredstava iz strukturnih fondova u postizanju konvergencije BDP-a per capita među

europskim regijama. Drugim riječima, model odgovara na pitanje kako na konvergenciju međusobno utječu kvaliteta institucija i izdaci iz EU fondova.

Konvergencija se izražava kao:

$$konvergencija = \frac{\partial g_{i,t}}{\partial y_{i,t-\tau}} = \beta_1 + \lambda_1 F_{it} + \lambda_2 Q_{it} + \theta F_{i,t} Q_{i,t} \quad (2)$$

gdje konvergencija ovisi o ukupnim izdacima iz fondova i kvaliteti institucija. Procjenjuje se dinamički panel model metodom sistemskog GMM-a (Arellano i Bond, 1991, Arellano i Bover, 1995 i Blundell i Bond, 1998).

Rezultati modela tumače se pomoću konturnog grafikona prikazanog na Slici 3. Brambor, Clark i Golder (2006) upućuju na najčešće pogreške u interpretaciji rezultata interakcijskih modela i na način na koji ih treba ispravno modelirati. Autori ističu da se rezultati regresijskih ispisa kod interakcijskih modela mogu tumačiti samo tako da nezavisna varijabla utječe na zavisnu varijablu u situacijama kada je drugi član u interakcijskoj varijabli nula, što je rijetko slučaj. Moguće je da je granični utjecaj nezavisne varijable na zavisnu varijablu statistički značajan u određenom rasponu vrijednosti drugog člana u interakcijskoj varijabli čak i u slučaju da interakcijska varijabla nije statistički značajna. Stoga nije moguće zaključke donositi samo na temelju statističke značajnosti varijabli u regresijskom ispisu. Umjesto toga rezultati se prikazuju pomoću grafikona graničnih utjecaja (u slučaju interakcijske varijable s dva člana) odnosno konturnog grafikona (u slučaju interakcijske varijable s tri člana).

## *Rezultati*

U Tablici 2. prikazani su rezultati procijenjenog modela s trostrukim interakcijskim članom. Predznaci ispred varijabli stope rasta stanovništva, ljudskog kapitala i ukupne faktorske produktivnosti su u skladu sa teorijskim očekivanjima. Sve tri varijable su statistički značajne pri čemu stopa rasta stanovništva ima negativan utjecaj na stopu gospodarskog rasta, a ljudski kapital i ukupna faktorska produktivnost pozitivan. Suprotno od rezultata prikazanih u Tablici 1., stopa zaposlenosti ima statistički značajan i negativan utjecaj na gospodarski rast, ali je magnituda utjecaja mala. Također, investicije nemaju statistički značajan utjecaj na gospodarski rast što nije očekivano s teorijskog stajališta niti je u skladu s rezultatima u Tablici 1. To bi se moglo objasniti uvođenjem ukupnih izdataka iz EU fondova u model.

Izdaci iz EU fondova imaju statistički značajan i pozitivan utjecaj na gospodarski rast, što može upućivati na to da izdaci iz EU fondova djelomično obuhvaćaju i vezu investicija i stope rasta BDP-a, stoga varijabla investicija samostalno nema dodatnu eksplanatornu moć u modelu.

Varijable izdaci iz EU fondova, inicijalna razina BDP-a per capita i indeks ekonomskih sloboda ne tumačimo individualno, premda je koeficijent pozitivan i statistički signifikantan. Zbog interakcijskih varijabli, vrijednosti parametara uz navedene varijable imaju utjecaj na stopu gospodarskog rasta samo u posebnom slučaju kada su druge dvije varijable nula. Umjesto toga, rezultate tumačimo pomoću konturnog grafikona prikazanog na Slici 3.

**Tablica 2. Rezultati modela s trostrukim interakcijskim članom**

| VARIJABLE | Stopa gospodarskog rasta |
|---|---|
| EU fondovi | 71.69** |
| | (34.79) |
| BDPpc(t-5) | 4.396 |
| | (3.731) |
| IES | 0.490 |
| | (0.373) |
| EU fondovi × BDPpc(t-5) | -7.300** |
| | (3.580) |
| EU fondovi × IES | -0.714** |
| | (0.347) |
| BDPpc(t-5)× IES | -0.0456 |
| | (0.0372) |
| EU fondovi × BDPpc(t-5) × IES | 0.0727** |
| | (0.0357) |
| Investicije | 1.122 |
| | (1.052) |
| Stopa rasta stanovništva | -1.560** |
| | (0.612) |
| Ljudski kapital | 0.188*** |
| | (0.0357) |
| TFP | 0.835*** |
| | (0.153) |
| Stopa zaposlenosti | -0.00668*** |
| | (0.00192) |
| Konstanta | -48.13 |
| | (37.37) |

Napomena: Robusne standardne pogreške u zagradama. *** $p < 0.01$, ** $p < 0.05$, * $p < 0.1$.
Izvor: Markušić (2026).

Na Slici 3. prikazan je konturni grafikon s rezultatima utjecaja kombinacije ukupnih izdataka iz EU fondova i Indeksa ekonomskih sloboda na konvergenciju. Na x-osi je Indeks ekonomskih sloboda, a na y-osi udio ukupnih izdataka iz europskih strukturnih fondova u BDP-u regije. Boje označavaju jačinu konvergencije, gdje plavo područje predstavlja jaču konvergenciju (izraženije negativna vrijednost na skali), a crveno područje slabiju (manje negativna vrijednost). Grafikon predstavlja sve kombinacije razine kvalitete institucija i izdataka iz EU fondova koje na razini značajnosti od 5 % utječu na konvergenciju.

Prvo se ističe da u cijelom rasponu postoji konvergencija BDP-a per capita među regijama, odnosno nema područja u kojem bi izdaci iz EU fondova i kvaliteta institucija pridonosili divergenciji. Rezultati su u skladu s ranijim rezultatima prikazanima u tablici 1., iako se način na koji su modeli postavljeni i procijenjeni razlikuje. Općenito se može zaključiti da postoji konvergencija BDP-a per capita i na razini zemalja i na razini regija u Europskoj uniji.

Drugo, grafikon prikazuje da kombinacija niske razine kvalitete institucija i visoke razine izdataka iz EU fondova pojačava konvergenciju BDP-a per capita regija. Povećanjem kvalitete institucija, izdaci iz EU fondova postupno imaju sve slabiji utjecaj na konvergenciju. Drugim riječima, držeći sve ostale faktore konstantnima, postoji određena mogućnost supstitucije između sredstava iz EU fondova i kvalitete institucija. Nekoliko je ograda vezano uz ovu interpretaciju.

Prvo, držeći sve faktore konstantnima (*ceteris paribus),* znači da se kvaliteta institucija ne povećava. Stoga regije sa slabim institucijama mogu konvergirati, ali prema niskoj ravnotežnoj razini dohotka: potpore ubrzavaju sustizanje, dok institucije određuju razinu na kojoj se ono zaustavlja. Upravo je to obrazac razvojne zamke koji se razrađuje u poglavlju 3.

**Slika 3. Rezultati utjecaja kombinacije ukupnih izdataka iz EU fondova i Indeksa ekonomskih sloboda na konvergenciju**

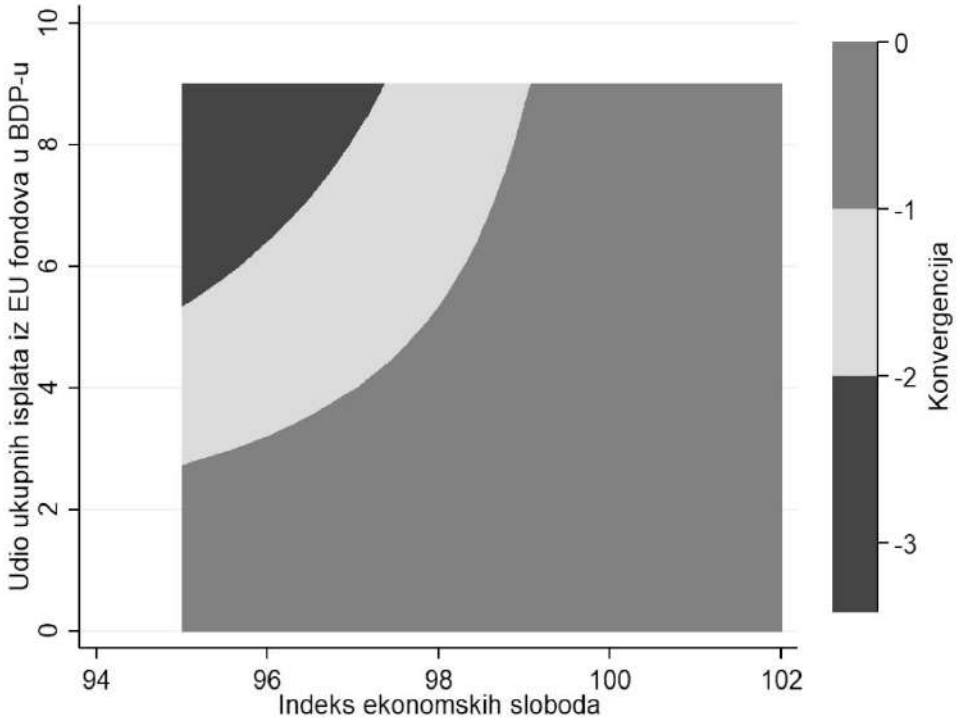


Izvor: Markušić (2026).

Drugo, ovom specifikacijom nisu identificirani opadajući prinosi na sredstva iz EU fondova jer izdaci u model ulaze linearno, pa je njihov granični učinak neovisan o vlastitoj razini; taj nalaz donose Becker, Egger i von Ehrlich (2012). Sama mogućnost supstitucije nosi, međutim, važno upozorenje. Sredstva iz EU fondova ne bi trebala supstituirati kvalitetne institucije, već ih moraju pomoći izgraditi. To je u skladu s brojnim nalazima o važnosti kvalitete institucija pri apsorpciji sredstava iz EU fondova (Becker, Egger i von Ehrlich, 2013). Druga su istraživanja (Butkus i sur., 2021) pokazala da dostatna kvaliteta institucija može ublažiti opadajuće prinose na sredstva iz EU fondova i pri visokom intenzitetu potpora. Rodríguez-Pose i Garcilazo (2015) pokazali su da kvaliteta uprave povećava prinose kohezijskih ulaganja te da iznad određene razine intenziteta potpora daljnji priljev sredstava bez poboljšanja uprave donosi malo dodatnog rasta.

Rezultati ovog istraživanja upućuju na to da kohezijska politika ostvaruje svoj konvergencijski cilj, ali i na to da brzina sustizanja sama po sebi nije dostatna mjera njezine uspješnosti. Manje razvijene regije primaju veće potpore jer je prihvatljivost vezana uz razinu BDP-a po stanovniku, a ne uz kvalitetu institucija; budući da su to u pravilu i regije slabije institucionalne kvalitete, one u promatranom razdoblju konvergiraju brže. Ako pri tome raste i kvaliteta institucija, sustizanje se nastavlja i nakon smanjenja priljeva sredstava. Kako institucionalna kvaliteta raste, doprinos dodatnih sredstava iz EU fondova na konvergenciju slabi, pa se o održivoj konvergenciji može govoriti u mjeri u kojoj jačanje institucija istodobno podiže i ravnotežnu razinu dohotka. Glavno upozorenje koje iz toga slijedi jest da visoka apsorpcija i brzo sustizanje mogu se javiti zajedno sa slabim institucijama, pa je ključno pitanje pretvaraju li se potpore u trajni rast produktivnosti ili samo u privremeno produbljivanje kapitala. Ta se razlika u nastavku rada razrađuje kroz razlikovanje apsorpcijskog i konvergencijskog kapaciteta.

# 3. RAZVOJNA ZAMKA: APSORPCIJSKI NASUPROT KONVERGENCIJSKOM KAPACITETU

## 3.1. Definicija i konceptualna pojašnjenja

Razvojna zamka je pojam koji se razvio iz koncepta zamke srednjeg dohotka kako bi se mogao primijeniti na razvijene zemlje i regije razvijenih zemalja. Stoga se u nastavku teksta paralelno objašnjavaju pojmovi zamke srednjeg dohotka i regionalne razvojne zamke te se raščlanjuju njihove specifičnosti.

Koncept zamke srednjeg dohotka odnosi se na zemlje koje su ostvarile uspješnu tranziciju s niskih na srednje razine dohotka, ali čija se dinamika rasta nakon toga značajno usporava, zbog čega se ne uspijevaju izdignuti na visoke razine dohotka (Gill, Kharas i Bhattasali, 2007). Riječ je, dakle, o zemljama koje su pronašle način kako prijeći s niskih na srednju razinu dohotka, ali im postojeći model rasta ne dopušta daljnji uspon prema visokim razinama dohotka. Načelno se zamka srednjeg dohotka može javiti na bilo kojoj razini dohotka, ali se najveći dio literature odnosi na zemlje srednjeg dohotka prema klasifikaciji Svjetske banke, dominantno na zemlje Južne Amerike, jugoistočne Azije te Bliskog istoka i sjeverne Afrike (Agénor, 2017).

U literaturi se, uz zamku srednjeg dohotka, razlikuju i koncept zamke siromaštva (Azariadis i Stachurski, 2005; Agénor i Aizenman, 2010) te koncept (regionalne) razvojne zamke (Diemer *i sur.*, 2022; Europska komisija i sur., 2020). Sva tri koncepta međusobno su povezana, ali se odnose na različite razine dohotka. Zamka siromaštva odnosi se na zemlje na niskim razinama dohotka u kojima izostaje bilo kakav značajniji gospodarski rast. Zamka srednjeg dohotka, kao što je već spomenuto, odnosi se na zemlje koje su dosegle srednju razinu dohotka, ali na njoj zastaju. Razvojna zamka se, s druge strane, u pravilu odnosi na regije ili zemlje unutar neke zajednice (poput Europske unije) koje su prema klasifikaciji Svjetske banke na visokim razinama dohotka, ali ne uspijevaju konvergirati nacionalnom ili nadnacionalnom prosjeku. U tom kontekstu se radi i o zamci izostanka konvergencije (engl. *non-convergence trap*).

Mehanizmi koji objašnjavaju zamku siromaštva razlikuju se od mehanizama zamke srednjeg dohotka, dok su mehanizmi zamke srednjeg dohotka i razvojne zamke vrlo slični budući da je razvojna zamka izveden i prilagođen pojam, izravno inspiriran konceptom zamke srednjeg dohotka. Tu poveznicu prva je eksplicitno uspostavila studija izrađena za Europsku komisiju (Europska komisija i sur., 2020), a kasnije je razrađena i u istraživanju Diemera i sur. (2022). Ta studija koncept zamke srednjeg dohotka, do tada primjenjivan isključivo na razini nacionalnih gospodarstava zemalja u razvoju, prvi put sustavno primjenjuje na regije Europske unije te uvodi i mjeri pojam regionalne razvojne zamke. Diemer i sur. (2022) taj su pristup dodatno teorijski i empirijski razradili, pokazujući da se regionalna razvojna zamka može javiti na različitim inicijalnim razinama dohotka regija, uključujući i regije koje su, unatoč relativno visokoj razini dohotka, dugoročno bilježile slabu dinamiku gospodarskog rasta i produktivnosti.

U kontekstu ovog rada, koncept razvojne zamke predstavlja relevantan okvir za tumačenje potencijalnog postojanja „zida“ u konvergenciji BDP-a per capita zemalja članica EU na razini od 80 % prosjeka Unije (preciznije od 75 % do 100 %), budući da se isti mehanizmi koji objašnjavaju usporavanje gospodarskog rasta zemalja srednjeg dohotka mogu primijeniti i na regije i zemlje Europske unije koje, unatoč relativno visokoj razini dohotka, ne uspijevaju postići konvergenciju.

Ključno je uočiti da se radi o zamci, dakle o (lošem) ravnotežnom stanju koje nema tendenciju promjene bez značajne intervencije (Agénor, 2017). Zamka je dijametralno suprotna konceptu konvergencije, koji sugerira da dolazi do

promjene, odnosno postupnog sustizanja među zemljama tijekom vremena. Kada se govori o regijama ili skupini zemalja poput EU, postojanje razvojne zamke najčešće sugerira postojanje višestrukih dugoročnih ravnoteža, što je usko povezano s konceptom klubova konvergencije. Naime, apsolutna konvergencija (među svim zemljama) implicira da će u dugom roku sve zemlje doseći istu razinu dohotka po glavi stanovnika ako imaju slične inicijalne uvjete. S druge strane, postojanje zamke, odnosno klubova konvergencije, sugerira da će zemlje u dugom roku doseći različite razine dohotka po glavi stanovnika te da će se razlike među njima zadržati, a potencijalno i produbiti.

Zamka srednjeg dohotka može se definirati apsolutno ili relativno (Agénor, 2017). U apsolutnim terminima, Svjetska banka razlikuje sljedeće razrede dohotka po glavi stanovnika: zemlje niskog dohotka su one s dohotkom do 1.175 USD, zemlje nižeg srednjeg dohotka od 1.176 do 4.635 USD, zemlje višeg srednjeg dohotka od 4.636 do 14.375 USD, dok su zemlje visokog dohotka one s dohotkom iznad 14.375 USD (Svjetska banka, 2026). U relativnim terminima promatra se koliko je zemlja blizu razini dohotka po glavi stanovnika SAD-a kao referentne točke. Takav pristup koriste Athukorala i Woo (2011) pri konstrukciji Catch-Up indeksa: zemlje koje su dosegle razinu višu od 55 % američkog BDP-a per capita smatraju se zemljama visokog dohotka, srednja je razina između 20 % i 55 %, dok je razina ispod 20 % niska.

U kontekstu regionalne razvojne zamke u EU najčešće se koristi relativna mjera razvijenosti u odnosu na europski prosjek. Diemer i sur. (2022) pri identifikaciji regija u razvojnoj zamci razlikuju regije prema inicijalnoj razini BDP-a per capita (u paritetu kupovne moći) relativno u odnosu na prosjek EU: regije s BDP-om per capita ispod 75 % prosjeka EU smatraju se nisko razvijenima, regije s udjelom između 75 % i 100 % prosjeka srednje razvijenima, dok se regije iznad 100 % prosjeka smatraju visoko razvijenima. Autori pokazuju da je rizik ulaska u razvojnu zamku najizraženiji upravo među srednje razvijenim regijama, odnosno onima čiji je BDP per capita između 75 % i 100 % prosjeka EU, što je u skladu s hipotezom o razvojnoj zamci na razini srednjeg dohotka.

Nijedna metoda identifikacije zamke srednjeg dohotka nije bez kritika (Agénor, 2017). Apsolutne razine dohotka često se smatraju arbitrarnima te su Eichengreen i sur. (2014) pokazali da je distribucija zemalja koje upadaju u zamku srednjeg dohotka bimodalna, što znači da zemlje upadaju u zamku

srednjeg dohotka pri različitim razinama dohotka. S druge strane, relativne mjere pate od problema paralelnog rasta referentne vrijednosti (benchmarka), odnosno gospodarskog rasta SAD-a u slučaju Catch-Up indeksa ili prosjeka EU u slučaju identificiranja regionalne razvojne zamke. Osobito u slučaju EU, uvijek će biti regija ili zemalja koje će biti ispod (ili iznad) prosjeka EU, bez obzira na to koliko je visok njihov životni standard.

## 3.2. Glavni uzroci nastanka zamke srednjeg dohotka

Najčešći uzrok upadanja u zamku srednjeg dohotka (a vrlo često i u regionalnu razvojnu zamku) je primjena istog modela rasta na niskoj i srednjoj razini dohotka. Naime, pri niskim razinama dohotka, zemlje najčešće ostvaruju rast kroz niske troškove rada i visoku konkurentnost rada te ulaganje u fizički kapital. Jednom kada se dosegne srednja razina dohotka, plaće rastu, troškovi rada se povećavaju, a prinos na fizički kapital pati od opadajućih prinosa. Stoga dolazi do značajnog usporavanja ekonomskog rasta jer se postojeći model rasta iscrpio. Zemlje u zamci srednjeg dohotka nemaju dovoljno visok ljudski kapital i inovacije da bi stvorile rast kroz porast produktivnosti. Stoga su zapele u sredini: nisu više dovoljno konkurentne da bi se natjecale sa zemljama niskog dohotka niti su dovoljno inovativne da bi se natjecale sa zemljama visokog dohotka (Gill, Kharas i Bhattasali, 2007; Agénor, 2017; Diemer *i sur.*, 2022).

Zbog toga je kao jedan od glavnih uzroka zamke srednjeg dohotka identificiran pad produktivnosti ili TFP-a (Eichengreen, Park i Shin, 2012; Agénor, 2017; Diemer *i sur.*, 2022). Taj se aspekt analizira i u ovome radu. Rast investicija koji izgrađuje fizički kapital ima ograničeni utjecaj na ekonomski rast zbog opadajućih prinosa. Tome najčešće pridonosi i rast troškova rada, zbog čega zemlja gubi konkurentnost u odnosu na zemlje niskog dohotka. Naime, zemlje u zamci srednjeg dohotka i dalje se fokusiraju na kvantitetu umjesto na kvalitetu proizvoda, forsirajući pogrešan model rasta.

Ostali čimbenici koji utječu na rast TFP-a, inovacije i gospodarski rast najčešće nisu dovoljno zastupljeni. Zemlje u zamci srednjeg dohotka pate od (1) nedovoljne kvalitete ljudskog kapitala koji bi stvarao inovacije. Problem je i (2) nedovoljna zaštita intelektualnog vlasništva te slabo izvršavanje ugovora, što izrazito negativno djeluje na inovacije i patente. (3) Pogrešna alokacija resursa također je jedan od problema koji se manifestira na način da

sposobni pojedinci koji mogu raditi u visokoproduktivnim inovativnim industrijama završe u drugim sektorima s manjim potencijalom rasta zbog viših ili sigurnijih plaća. Za razliku od nedovoljne količine ljudskog kapitala, ovdje se radi o problemu pogrešne distribucije tog kapitala (vidi Agénor i Canuto, 2015). Sposobni radnici najčešće izbjegavaju rizične poduzetničke aktivnosti vezane uz inovacije zbog loše zaštite intelektualnog vlasništva. (4) Nedostatak adekvatne i sofisticirane infrastrukture te (5) ograničen pristup financiranju putem rizičnog kapitala također su potencijalni uzroci sporog rasta produktivnosti, odnosno TFP-a (Agénor, 2017). Infrastruktura se može podijeliti u osnovnu i naprednu infrastrukturu. Osnovna infrastruktura uključuje ceste, električnu energiju, komunalije i osnovne načine komunikacije. Napredna infrastruktura s druge strane uključuje napredne informacijsko-komunikacijske tehnologije i komunikacijske mreže.

## 3.3. Sličnosti i razlike regionalne zamke u odnosu na zamku srednjeg dohotka

Premda je regionalna razvojna zamka nešto noviji koncept (Diemer *i sur.*, 2022), osnovna je ideja nastala vrlo rano kada je primijećeno da se zemlje EU ne razvijaju podjednako, već se razvoj događa različitim brzinama (Fagerberg i Verspagen, 1996). Također je ustanovljeno da regije koje se nalaze u razvojnoj zamci imaju vrlo slične karakteristike kao i zemlje u zamci srednjeg dohotka (Iammarino, Rodriguez-Pose i Storper, 2019). Tako Iammarino, Rodriguez-Pose i Storper (2019) uočavaju velike razlike među europskim regijama u pogledu rasta BDP-a, industrijske strukture, zaposlenosti, obrazovanja, produktivnosti, inovacija, kao i urbanizacije i demografije. Međutim, najveće razlike pokazuju regije srednje razine dohotka.

Diemer i sur. (2022) sistematiziraju karakteristike koje regije u razvojnoj zamci dijele sa zemljama u zamci srednjeg dohotka. Prvo, njihova je razina troškova previsoka da bi bile konkurentne u proizvodnji osnovnih dobara i usluga s manje razvijenim regijama unutar EU te sa zemljama niskog i nižeg srednjeg dohotka izvan granica EU. Drugo, razina vještina i inovacijskih kapaciteta je ispod one u regijama visokog dohotka EU, zbog čega nisu konkurentne u proizvodnji naprednih i tehnološki intenzivnih dobara i usluga. Treće, njihova je ekonomska stagnacija dodatno pojačana procesima premještanja proizvodnje u inozemstvo (engl. *offshoring*), kao i ograničenim kapacitetima za privlačenje izravnih stranih ulaganja i/ili za podupiranje

internacionalizacije domaćih poduzeća. Rezultat su dugotrajna razdoblja stagnacije, iznadprosječne razine nezaposlenosti, posebice dugotrajne nezaposlenosti, te u pojedinim slučajevima i demografski pad. Takve regije stoga ostaju zarobljene u sredini: preskupe za konkurenciju troškovima, a nedovoljno inovativne za konkurenciju znanjem.

Međutim, postoje i određene razlike između zemalja ili regija u regionalnoj razvojnoj zamci u odnosu na zemlje u zamci srednjeg dohotka. Prvo, regionalna zamka u EU javlja se na znatno višoj razini BDP-a per capita nego kod zemalja u zamci srednjeg dohotka. Regije u razvojnoj zamci najčešće se nalaze u rasponu između 75 % i 100 % prosjeka EU, što znači da je, globalno gledajući, riječ o visoko razvijenim područjima, jer je i sam prosjek EU visok. No te regije trpe dugotrajnu stagnaciju te zaostaju za drugim regijama po rastu i stvaranju radnih mjesta. Drugo, stagnacija ne slijedi nužno nakon uspješnog prijelaza iz niskog u srednji dohodak, već se može pojaviti na različitim razinama dohotka, uključujući i prijelaz s više na srednju razinu dohotka.

Europska komisija i sur. (2020) razlikuju tri skupine takvih regija. Prva, i vjerojatno najbrojnija, obuhvaća nekadašnje industrijske regije koje su u posljednjim desetljećima doživjele znatan pad prerađivačke industrije, često zbog premještanja proizvodnje u inozemstvo, što je smanjilo zaposlenost i zaustavilo rast stanovništva, uz neodgovarajuću razinu obrazovanja i vještina radne snage te nisku participaciju na tržištu rada. Ta skupina srednjoj razini dohotka pristupa „odozgo“, jer su te regije relativno nazadovale. Druga skupina srednjoj se razini približila „odozdo“: to su prije zaostale regije koje su prošle razdoblja brzog rasta, ali su ostale zarobljene na razinama između 75 % i 90 % prosjeka EU. Njihova je prednost kombinacija privlačnih životnih uvjeta i niskih troškova života, zbog čega ostaju demografski dinamične, kao i radna mjesta u lokalnim, izvozno neorijentiranim uslugama (engl. *nontradables*). Ipak, takva radna mjesta imaju ograničen potencijal te drže produktivnost i dohodak po glavi stanovnika niskima. Treću skupinu čine regije koje su cijelo vrijeme ostale u sredini: nekada su dosegnule srednju razinu dohotka i na njoj su i ostale, a nikada nisu ostvarile rast dovoljan da poprave svoj relativni položaj u odnosu na ostale regije EU.

U nastavku se razmatraju razvojne strategije koje omogućavaju zemljama ili regijama izlazak iz razvojnih zamki u ovisnosti o stupnju razvoja.

## 3.4. Izlazak iz zamke: apsorpcijski vs. konvergencijski kapacitet (strategija 3i)

Razlikovanje apsorpcijskog od konvergencijskog kapaciteta omogućava razumijevanje zašto zemlje ili regije ulaze u zamku srednjeg dohotka. Apsorpcijski kapacitet odnosi se na sposobnost gospodarstva da raspoloživa sredstva, primjerice transfere iz strukturnih fondova EU, pretvori u investicije i time podigne razinu kapitala, a konvergencijski kapacitet na sposobnost da se ta ulaganja pretoče u trajni rast produktivnosti, tehnološki napredak i kvalitetne institucije. Ta dva kapaciteta nisu snažno korelirana: Becker, Egger i von Ehrlich (2013) pokazuju da učinak transfera presudno ovisi o ljudskom kapitalu i kvaliteti institucija regije primatelja, pa se visoka stopa iskorištenosti sredstava može ostvariti i uz zanemariv doprinos rastu. Razlika između tih kapaciteta odgovara razlici između apsorpcijskog rasta, koji je tranzitoran i uglavnom traje dok traje priljev, i konvergencijskog rasta, koji preživljava njegov prestanak. Zamka srednjeg dohotka i razvojna zamka mogu se promatrati kao stanje visokog apsorpcijskog, ali niskog konvergencijskog kapaciteta.

Upravo tu logiku formalizira strategija 3i iz izvješća Svjetske banke (2024). Prema tom okviru, prikladna kombinacija razvojnih strategija ovisi o razvojnom statusu zemlje i odvija se u fazama. Zemlje niskog dohotka rastu prvenstveno kroz investicije, odnosno akumulaciju fizičkog kapitala i izgradnju osnovne infrastrukture. Na nižim srednjim razinama dohotka investicije nisu dovoljne te ih je potrebno upariti s infuzijom, odnosno s usvajanjem i difuzijom tehnologija koje već postoje na svjetskoj tehnološkoj granici, najčešće putem izravnih stranih ulaganja (engl. foreign direct investment – FDI) i uključivanja u globalne vrijednosne lance. Tek na višim srednjim razinama dohotka presudna postaje treća komponenta, inovacija, odnosno pomicanje same tehnološke granice. Ključna poruka izvješća nije da su investicije nevažne, nego da je oslanjanje isključivo na prvu komponentu dugoročno neodrživo: zemlje zapadaju u zamku jer predugo ostaju u fazi 1i, umjesto da pravovremeno prijeđu na 2i i 3i. Za zemlje EU to je posebno relevantno, jer strukturni fondovi po svojoj konstrukciji financiraju upravo investicijsku fazu, pa je pitanje održivosti konvergencije pitanje pretvaraju li se ta ulaganja u infuziju i inovaciju ili ostaju puko produbljivanje kapitala.

Prijelaz između faza teorijski se najbolje objašnjava fenomenom kreativne destrukcije. Schumpeter (1942) rast promatra kao proces u kojem novi proizvodi, tehnologije i poduzeća istiskuju postojeće, pa je rast neodvojiv od

realokacije resursa i destrukcije postojećih proizvoda i praksi. Aghion i Howitt (1992) taj su mehanizam formalizirali u modelu endogenog rasta u kojem inovacije proizlaze iz ulaganja u istraživanje i razvoj motiviranog privremenim monopolskim položajem, a nove inovacije potencijalno uništavaju prethodne. Rast tada ovisi o očekivanoj vrijednosti inovacije, dakle o zaštiti intelektualnog vlasništva, pristupu financiranju i izvršavanju ugovora, ali i o slobodi ulaska i izlaska poduzeća, jer bez izlaska neuspješnih nema realokacije. Acemoglu, Aghion i Zilibotti (2006) pokazuju da optimalna kombinacija politika ovisi o udaljenosti od tehnološke granice: aranžmani koji podupiru rast daleko od granice, poput zaštite velikih etabliranih proizvođača, postaju kočnica rasta kada rast zahtijeva selekciju i ulazak novih poduzeća. Aghion i Bircan (2017) na tome temelje schumpeterovsku interpretaciju zamke srednjeg dohotka kao neuspjeha prijelaza s imitacije na inovaciju. Akcigit i Kerr (2018) dodatno upozoravaju da nije važna samo količina, nego i sastav inovacija. Inkrementalne inovacije koje etablirani proizvođači provode na vlastitim proizvodima djeluju drukčije od radikalnih inovacija koje najčešće dolaze od novih poduzeća i koje su presudne za agregatni rast.

Iz toga slijedi da se prikladan set politika mijenja s razvojnim statusom. Na nižim razinama relativnog dohotka prioritet ostaje osnovna infrastruktura, širenje obrazovanja i otvorenost prema stranim investicijama i uvozu tehnologije, dakle politike koje jačaju apsorpcijski kapacitet. Kako se zemlja približava prosjeku razvijenih, težište se mora premjestiti na politike koje jačaju konvergencijski kapacitet: kvalitetu, a ne samo obuhvat ljudskog kapitala, zaštitu intelektualnog vlasništva i pravnu sigurnost, zaštitu tržišnog natjecanja i uklanjanje barijera ulasku, funkcionalan okvir za stečaj, razvoj rizičnog kapitala i naprednu digitalnu infrastrukturu. Zajednički im je nazivnik sprječavanje politika koje zadržavaju status quo, koje su u schumpeterovskom okviru glavni mehanizam blokade prijelaza. U kontekstu kohezijske politike to znači pomak s maksimiziranja apsorpcije na maksimiziranje učinka, odnosno usmjeravanje sredstava u razmjenjive sektore, produktivnost i institucije, umjesto u potražno vođena ulaganja bez trajnog učinka na potencijalni output.

Rezultati konvergencijske analize iz prvog dijela rada s tim su okvirom u posrednom, ali informativnom odnosu. Procjene ne potvrđuju postojanje „zida“ u konvergenciji na razini od približno 80 % prosjeka EU: konvergencija je statistički značajna, a njezina procijenjena brzina statistički je jednaka u poduzorku zemalja ispod i u poduzorku zemalja iznad tog praga.

Taj nalaz treba tumačiti s rezervom jer je specifikacija modela relativno jednostavna, pa je moguće da ne obuhvaća nelinearnosti koje literatura o razvojnoj zamci pretpostavlja. Naime, dio literature nalazi zaustavljanje konvergencije regija u rasponu oko 80 % prosjeka BDP-a EU, uz ograničenja robusnosti iznesena u poglavlju 2.2. (Diaz del Hoyo *i sur.*, 2017; Diemer i *sur.*, 2022; Europska komisija, 2024). Važnije je, međutim, da izostanak zida ne znači izostanak zamke: brzina konvergencije mjeri tempo sustizanja, ali ne govori o sastavu rasta koji ga proizvodi, a upravo je sastav ono što 3i okvir i teorija kreativne destrukcije identificiraju kao presudno. Indikativno je u tom smislu da su doprinosi TFP-a i ljudskog kapitala značajni samo u poduzorku zemalja iznad 80 % prosjeka EU, dok ispod tog praga značajne ostaju samo investicije, što je obrazac konzistentan s tvrdnjom da se pokretači rasta mijenjaju s razvojnim statusom. Provjera te hipoteze zahtijeva dekompoziciju rasta na doprinose kapitala, rada i TFP-a, za što se u nastavku rada koristi računovodstvo rasta.

# 4. RAČUNOVODSTVO RASTA ZA ANALIZU APSORPCIJSKOG I KONVERGENCIJSKOG KAPACITETA

Konvergencijska analiza mjeri brzinu sustizanja, ali ne i sastav rasta koji ga proizvodi. Upravo je sastav ono što razlikuje apsorpcijski od konvergencijskog kapaciteta i što strategija 3i prepoznaje kao presudno za izlazak iz razvojne zamke. Ista brzina konvergencije može biti rezultat produbljivanja kapitala financiranog transferima ili rasta produktivnosti, a te dvije mogućnosti imaju bitno različite implikacije za održivost rasta. Računovodstvo rasta (Solow, 1957; Jorgenson i Griliches, 1967) omogućuje tu provjeru jer rast dekomponira na doprinose pojedinih faktora proizvodnje i na rezidual koji predstavlja rast produktivnosti (engl. total factor productivity – TFP). Ukratko, rast baziran na fizičkom kapitalu nije dugoročno održiv zbog opadajućih prinosa kapitala, dok se rast baziran na produktivnosti i tehnologiji (TFP) smatra dugoročno održivim.

## 4.1. Podaci

Dekompozicija se provodi za svih 27 zemalja članica EU, a rezultati se u ovom poglavlju fokusiraju na Hrvatsku i Portugal kao zemlju s iskustvom

dugotrajnog zastoja u konvergenciji. Koriste se tri baze podataka jer nijedna sama ne pokriva sve što je potrebno. Penn World Table 11.0 (Feenstra, Inklaar i Timmer, 2015) daje najdužu vremensku seriju od 1950. do 2023. godine, te podatke o uslugama kapitala i indeks ljudskog kapitala. Za nove zemlje članice, uključujući Hrvatsku, podaci su dostupni od 1995. EU KLEMS & INTANProd, izdanje 2023. (Bontadini i sur., 2023), pokriva razdoblje od 1995. do 2021. godine i nudi najfiniju podjelu: kapital je razdvojen na materijalni ICT (engl. *Information and communication technologies*), materijalni bez ICT-a te nematerijalni, a doprinos rada na odrađene sate i na kvalitetu, odnosno sastav radne snage (ljudski kapital). Za Hrvatsku i većinu novih zemalja članica, ovako fina podjela je dostupna tek od 2009. To stvara određeni kompromis *(trade-off)* između dužine vremenske serije i dubine dekompozicije faktora rasta. Konačno, AMECO, proljetna verzija 2026. (Europska komisija, 2026), pokriva razdoblje od 1960. do 2027. godine, jedina ima istovjetnu definiciju za sve članice i jedina seže do razdoblja provedbe Mehanizma za oporavak i otpornost (u Hrvatskoj je to Nacionalni plan oporavka i otpornosti – NPOO), pri čemu su 2026. i 2027. prognoze pa se prikazuju odvojeno. Za Hrvatsku i većinu novih zemalja članica podaci su dostupni od 1995. godine.

## 4.2. Metode

Polazi se od agregatne proizvodne funkcije uz pretpostavku konstantnih prinosa na opseg i konkurentnih tržišta faktora, pri čemu se elastičnosti outputa mjere udjelima faktora u dohotku. Rast se tada dekomponira kao:

$$\Delta \ln Y_t = \overline{s}_t \Delta \ln H_t + (1 - \overline{s}_t) \Delta \ln K_t + \overline{s}_t \Delta \ln hc_t + \Delta \ln A_t \qquad (3)$$

gdje je $Y_t$ bruto domaći proizvod, $H_t$ ukupan broj odrađenih sati, $K_t$ su usluge kapitala, $hc_t$ je indeks ljudskog kapitala, $A_t$ ukupna faktorska produktivnost (TFP), a $\overline{s}$ Törnqvistov ponder udjela rada u dohotku, definiran kao prosjek udjela u godinama $t$ i $t-1$ (Diewert, 1976):

$$\overline{s}_t = \frac{s_t + s_{t-1}}{2} \qquad (4)$$

Sve su veličine izražene u postotnim bodovima koristeći aproksimaciju logaritamskih diferencija. Input rada čine ukupni odrađeni sati, a ne broj zaposlenih, čime se odvaja promjena broja radnika od promjene prosječnog radnog vremena. Doprinos TFP-a dobiva se kao rezidual.

Dekompozicija se izravno preslikava na strategiju 3i. Doprinos fizičkog kapitala odgovara investicijama, prvoj komponenti, jer mjeri produbljivanje kapitala. Doprinos kvalitete rada (ljudskog kapitala), zajedno s doprinosom ICT i nematerijalnog kapitala, odgovara infuziji, drugoj komponenti, jer je riječ o usvajanju tehnologije koja već postoji na svjetskoj tehnološkoj granici, bilo utjelovljene u uvezenoj opremi i softveru, bilo u vještinama radne snage. Doprinos TFP-a odgovara inovaciji, trećoj komponenti, jer mjeri pomak same granice. Doprinos odrađenih sati nije dio 3i okvira: on je čista akumulacija faktora i pripada apsorpcijskom kapacitetu. Puna podjela na tri komponente moguća je samo u EU KLEMS-u, jer jedino on razdvaja vrste imovine; u PWT-u se druga i treća komponenta razdvajaju samo preko ljudskog kapitala i TFP-a.

AMECO se u punu 3i podjelu ne može uklopiti zbog raspoloživosti podataka. Ta baza nema indeks kvalitete rada ni podjelu kapitala po vrstama imovine, pa se infuzija i inovacija iz nje ne mogu razdvojiti: dobivaju se samo doprinos rada, doprinos kapitala i rezidual koji objedinjuje ljudski kapital i TFP. Rezultati iz baze AMECO stoga prikazuju samo apsorpcijski kapacitet (kapital i rad) i konvergencijski kapacitet (ljudski kapital i TFP). Ključna je prednost ove baze to što su serije dostupne do 2027. godine (pri čemu su podaci za 2026. i 2027. godinu projekcije), ali se za dekompoziciju na tri komponente moraju koristiti baze PWT i EU KLEMS.

Rezultate treba čitati uz nekoliko ograda. TFP je rezidual, pa uz tehnološki napredak upija i pogrešku mjerenja, promjene u iskorištenosti kapaciteta i realokaciju resursa među sektorima, što je u recesijskim godinama posebno izraženo. Ponderiranje udjelima u dohotku pretpostavlja konstantne prinose na opseg i konkurentna tržišta faktora, što su jake pretpostavke. AMECO uz to koristi neto zalihu kapitala umjesto usluga kapitala, pa je doprinos kapitala iz te baze sustavno podcijenjen, a konvergencijska košarica (ljudski kapital i TFP) precijenjena.

## 4.3. Rezultati

U nastavku su prikazani rezultati računovodstva rasta. Analiza je provedena za sve zemlje EU, ali se u radu fokusiramo na Hrvatsku i Portugal. Naime, Portugal je odabran kao zemlja za koju se često navodi da se nalazi u zamci srednjeg dohotka ili razvojnoj zamci, jer nakon što je prvotno bio iznad 90 %

prosjeka EU po veličini BDP-a per capita, došlo je do relativnog pada i već dulje vrijeme ne uspijeva probiti granicu od 80 %, što je prikazano na Slici 2.

Ukratko, rezultati pokazuju da Portugal doista pokazuje karakteristike zemlje koja se nalazi u zamci srednjeg dohotka, s vrlo niskim doprinosom TFP-a gospodarskom rastu te sa snažnom akumulacijom rada i fizičkog kapitala. Hrvatska pak pokazuje nešto drugačije karakteristike, s većim doprinosom TFP-a i ljudskog kapitala rastu BDP-a. Međutim, hrvatski konvergencijski kapacitet u razdoblju od 1996. do 2023. iznosi 1,01 postotni bod godišnje, što je jedanaesto mjesto među 27 članica i niže od vrijednosti baltičkih zemalja, Slovačke, Poljske, Rumunjske i Slovenije te Mađarske i Cipra. Unutar tog prosjeka izdvaja se razdoblje od 2021. do 2023. godine, u kojem je doprinos konvergencijske košarice izrazito visok. Nadalje, najnoviji podaci iz baze AMECO pokazuju da se od 2024. sastav rasta mijenja te da prevladava akumulacija rada i fizičkog kapitala. Pitanje koje iz toga proizlazi je hoće li Hrvatska zadržati svoju solidnu poziciju koju je izgradila u razdoblju između 2021. i 2023. ili je to bila prolazna pojava kojoj je došao kraj te se vraćamo prosječnosti. Stoga je vrlo važno realocirati raspoložive resurse u djelatnosti znanosti te istraživanja i razvoja kako bi se nastavio održivi rast TFP-a i ljudskog kapitala.

Slika 4. prikazuje dekompoziciju rasta BDP-a za Hrvatsku i Portugal prema trima bazama podataka. Gornji dio slike prikazuje rezultate iz baze Penn World Table. Doprinos ukupne faktorske produktivnosti hrvatskom rastu pozitivan je u većini godina, ali umjerene veličine, uz izražene negativne vrijednosti u recesijskim razdobljima od 2008. do 2014. te u 2020. godini. Izrazito odstupanje predstavlja razdoblje od 2021. do 2023., u kojem je produktivnost glavni generator rasta. Doprinos ljudskog kapitala konstantno je pozitivan i stabilan, između 0,60 i 0,89 postotnih bodova, najviši prosječni doprinos među članicama EU.

U 2019. godini zabilježen je skok prosječnog broja odrađenih sati po zaposlenome u bazama Penn World Table i EU KLEMS, s 1811 na 1996 sati godišnje (oko 10 %), pri čemu se nova razina zadržava i u kasnijim godinama. Malo je vjerojatno da je riječ o stvarnoj promjeni radnog vremena, već se prije radi o promjeni statističkog obuhvata. Zbog toga doprinos rada u toj godini ispada neuobičajeno visok, a rezidual negativan. U bazi AMECO takav skok nije zabilježen, a razine odrađenih sati u toj bazi od 2019. godine nadalje poklapaju se s onima iz baze Penn World Table, što dodatno potvrđuje da je riječ o statističkom artefaktu.

**Slika 4. Računovodstvo rasta: dekompozicija rasta BDP-a prema tri baze podataka**

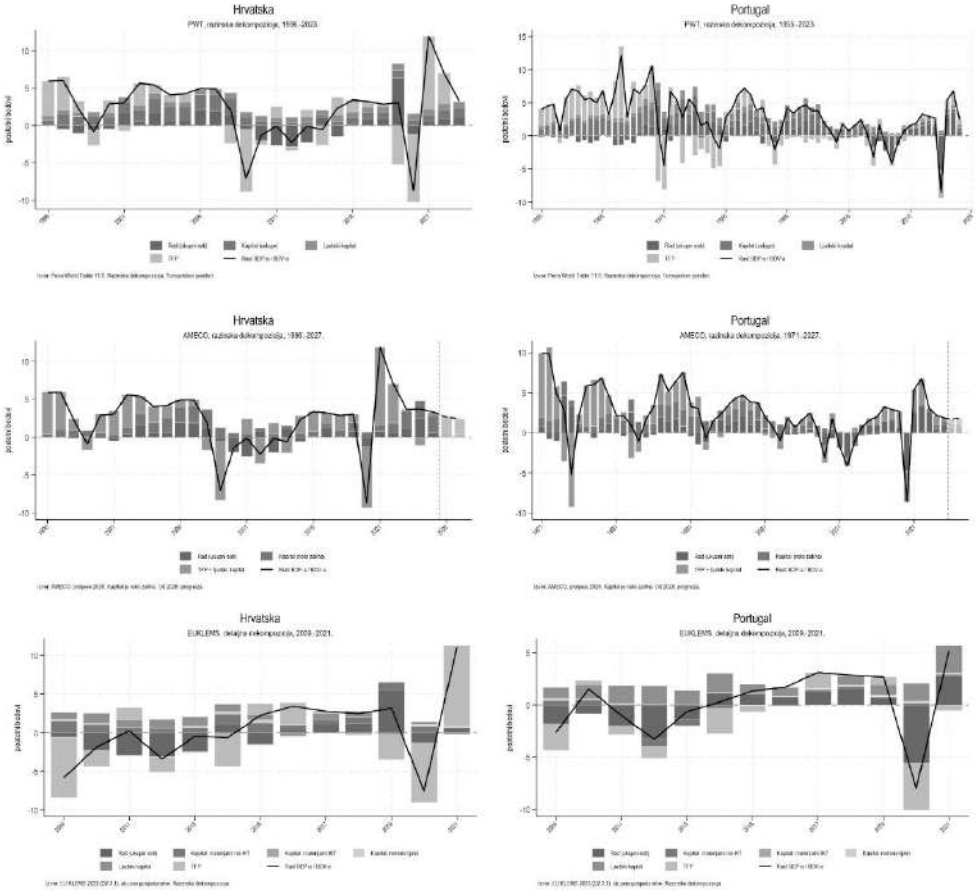


Izvor: Penn World Table 11.0, AMECO (proljeće 2026.) i EU KLEMS 2023 (D2.3.1); izračun autora.

**Slika 5. Konvergencijska košarica nasuprot doprinosu kapitala rastu**

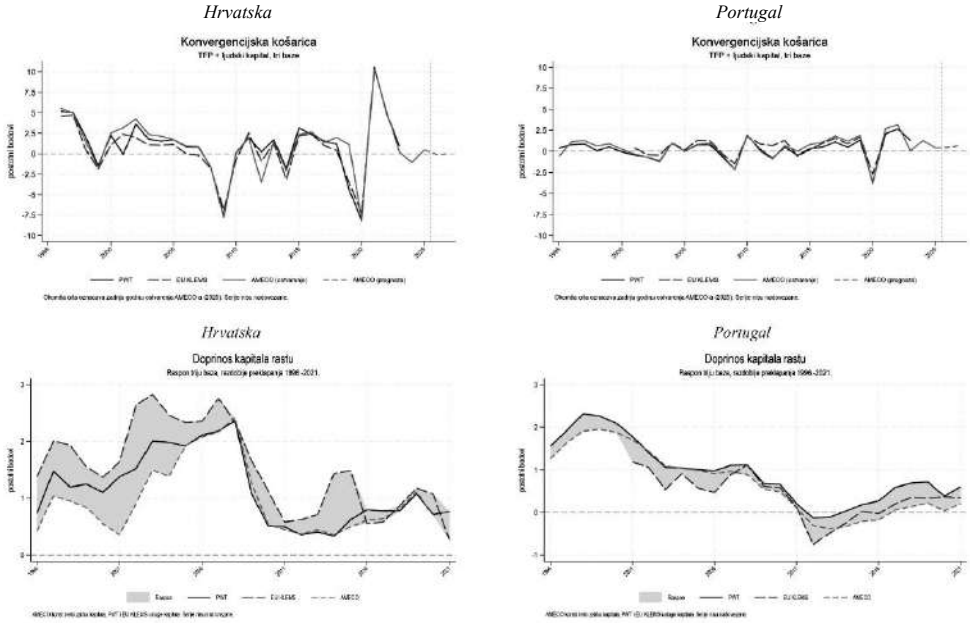


Izvor: Penn World Table 11.0, AMECO (proljeće 2026.) i EU KLEMS 2023 (D2.3.1); izračun autora.

Slučaj Portugala doslovno priča drugu priču, onu o zamci srednjeg dohotka. Nakon 1990. godine drastično se smanjuje utjecaj TFP-a na ekonomski rast (gotovo da iščezava), njegovu ulogu preuzima ljudski kapital do sredine 2000-ih godina, a nakon toga se rast značajno bazira na akumulaciji rada i fizičkog kapitala. To ne mora nužno biti loše, jer su Tica, Viljevac i Matić (2023) na temelju regresija rasta za posttranzicijske zemlje pokazali da je stopa zaposlenosti najvažniji faktor rasta čak i u dugom roku, nakon 30 godina. Nakon stope zaposlenosti, inicijalni BDP se pokazao kao druga najvažnija stavka u objašnjavanju ekonomskog rasta.

U ukupnom promatranom razdoblju, Portugal ima drugi najveći doprinos ljudskog kapitala u EU, 0,51 postotni bod (najveći doprinos ima Hrvatska od 0,70), uz vrlo nizak doprinos ukupne faktorske produktivnosti od −0,25 postotnih bodova. Riječ je dakle o zemlji koja je uspješno provela fazu infuzije, izgradila ljudski kapital i usvojila postojeće tehnologije, ali nije napravila prijelaz u fazu inovacije, dakle zapela je na drugom prijelazu prema

strategiji 3i. To je konzistentno sa schumpeterovskim tumačenjem zamke srednjeg dohotka kao neuspjeha prijelaza s imitacije na inovaciju (Aghion i Bircan, 2017) i objašnjava zašto portugalsko iskustvo ne predstavlja upozorenje samo zemljama na nižim razinama razvoja.

S obzirom na to da baza AMECO ne mjeri kvalitetu rada odvojeno, rezidual iz te baze objedinjuje TFP i ljudski kapital, što se može smatrati proširenim konvergencijskim kapacitetom. To je prikazano u drugom redu Slike 4. Rezultati su vrlo slični onima iz PWT baze podataka, ali je glavna dodana vrijednost to što AMECO pokriva dulje razdoblje: službeni podaci idu do 2025., a projekcije pokrivaju razdoblje 2026. i 2027. godine. Do 2023. godine vidljiva je vrlo važna uloga objedinjenog TFP-a i ljudskog kapitala u objašnjavanju ekonomskog rasta Hrvatske. Međutim, rezultati za recentne godine govore da nakon 2023. godine rast u Hrvatskoj primarno proizlazi iz akumulacije kapitala i rada. To je odstupanje od dotadašnjih kretanja, a može se protumačiti kroz izrazito zategnuto tržište rada, rekordno nisku stopu nezaposlenosti, te visoki intenzitet građevinskih radova, dominantno na obnovi objekata stradalih u potresu (Arčabić, 2025). Projekcijsko razdoblje za 2026. i 2027. godinu treba uzeti s rezervom, ali ako se ovakav trend doista nastavi, Hrvatska riskira izgubiti konvergencijski potencijal koji je došao na svoj vrhunac između 2021. i 2023. godine. U slučaju Portugala, rast u recentnom razdoblju značajnije usporava, a glavni generatori tog rasta su i dalje akumulacija rada i kombinacija TFP-a i ljudskog kapitala. Akumulacija fizičkog kapitala u recentnom razdoblju ima znatno manju ulogu u odnosu na onu koju je imala do globalne financijske krize.

Naposljetku, rezultati računovodstva rasta na temelju EU KLEMS baze podataka usklađeni su s dosadašnjim zaključcima za Hrvatsku, naglašavajući utjecaj TFP-a u 2021. godini (treći redak Slike 4.). Godina 2019. i ovdje predstavlja izdvojenicu (*outlier*) zbog prekida u seriji radnih sati. Doprinos fizičkog kapitala i svih njegovih podvrsta (ICT kapital, kapital koji ne uključuje ICT te nematerijalni kapital) je konstantno pozitivan, kao što je i očekivano, ali ima relativno skroman doprinos rastu. Najveći problem ove baze je kratak obuhvat pune dekompozicije od 2009. do 2021. U slučaju Portugala vidljiv je nešto snažniji utjecaj ljudskog kapitala na rast, ali ponovno ograničen utjecaj TFP-a.

Slika 5. usporedno prikazuje konvergencijsku košaricu izračunatu prema sve tri baze podataka za Hrvatsku i Portugal (gornji dio slike) koja se sastoji od zbroja TFP-a i ljudskog kapitala. Donji dio Slike 5. usporedno prikazuje

doprinos kapitala rastu za iste dvije zemlje prema sve tri baze podataka. Vidljivo je da su mjere konvergencijske košarice iz sve tri baze podataka vrlo usklađene i govore o gotovo identičnoj dinamici. S druge strane, zbog različitih definicija kapitala među bazama, prikazani su različiti rasponi utjecaja kapitala na ekonomski rast, pri čemu je očekivano AMECO najniži, jer mjeri samo neto zalihu kapitala umjesto usluga kapitala.

U Hrvatskoj je konvergencijska košarica znatno volatilnija nego u Portugalu, i to je ključna razlika između dviju zemalja. Portugalska je košarica stabilna, ali niska, i govori o trajno ograničenom doprinosu produktivnosti rastu. Hrvatska bilježi više prosječne vrijednosti, ali one dominantno proizlaze iz nekoliko godina snažnog rasta, dok je u dugim razdobljima doprinos blizu nule ili negativan. Volatilnost te vrste nije poželjna niti sugerira održivi rast produktivnosti. Za ocjenu konvergencijskog kapaciteta ključno jest je li doprinos produktivnosti trajan. Sve tri baze u tom pogledu daju usklađenu sliku, uključujući i nalaz da nakon 2023. godine konvergencijski doprinos u Hrvatskoj praktički nestaje. Podaci u ovome radu ne pokrivaju razdoblje tranzicije, ali su Raguž Krištić, Družić i Tica (2016) pokazali da je tranzicija uzrokovala pozitivan strukturni prekid u TFP-u te da je nakon tranzicije udio TFP-a u gospodarskom rastu povećan. No u svome radu ne govore o volatilnosti TFP-a.

Ako se promatra doprinos fizičkog kapitala rastu, u obje je zemlje vidljiv pad udjela kapitala u rastu tijekom vremena. U ovom slučaju značajnijih razlika među zemljama nema. Detaljan doprinos rada, kapitala, ljudskog kapitala, ukupne faktorske produktivnosti te sumarno konvergencijskog i apsorpcijskog kapaciteta za Hrvatsku i Portugal prikazan je u Prilogu A u Tablici A1 po razdobljima. Rezultati iz Tablice A1 potvrđuju gore navedene zaključke.

Naposljetku, identična analiza je provedena i za preostalih 25 zemalja članica EU. Rezultati za sve zemlje sumarno su prikazani u Prilogu A u Tablici A2. Radi jednostavnosti, tablica prikazuje rezultate samo za PWT bazu podataka, premda su rezultati za ostale baze usporedivi i usklađeni. Iz Tablice A2. vidljivo je da su zemlje s najbržim rastom u promatranom razdoblju ujedno ostvarile i najveći konvergencijski kapacitet. To se prije svega odnosi na baltičke zemlje, gdje konvergencijska košarica iznosi 2,71 postotni bod u Latviji, 2,19 u Litvi i 2,04 u Estoniji, zatim na Slovačku s 1,90, Irsku s 1,58 te Poljsku i Rumunjsku s 1,49 postotnih bodova. Hrvatska pripada skupini brzorastućih zemalja po stopi rasta BDP-a, koja iznosi 2,41 posto godišnje,

ali ne i po konvergencijskom kapacitetu, gdje s 1,01 postotnim bodom zauzima jedanaesto mjesto među 27 članica, iza svih navedenih zemalja i uz vrijednost jednaku malteškoj. Hrvatski doprinos ukupne faktorske produktivnosti od 0,31 postotnog boda zauzima petnaesto mjesto i ispod je prosjeka novih članica koji iznosi jedan postotni bod. Struktura hrvatskog rasta u promatranom razdoblju stoga je bliža prosjeku EU nego skupini usporedivih posttranzicijskih zemalja.

Usporedba svih 27 članica otkriva obrazac koji nadilazi pojedinačne slučajeve. Prema Tablici A2., Hrvatska ima najveći prosječni doprinos ljudskog kapitala rastu u cijeloj EU, 0,70 postotnih bodova godišnje, ispred Portugala s 0,51 i Malte s 0,50 postotnih bodova. Istodobno je hrvatski doprinos ukupne faktorske produktivnosti 0,31 postotni bod, dakle petnaesto mjesto. Međutim, korelacija između doprinosa ljudskog kapitala i doprinosa produktivnosti preko 27 članica praktički je nula, što znači da među zemljama EU praktički ne postoji veza između rasta obrazovne strukture radne snage i rasta produktivnosti.

Taj nalaz izravno potvrđuje mehanizam koji literatura o zamci srednjeg dohotka opisuje kao pogrešnu alokaciju ljudskog kapitala (Agénor i Canuto, 2015; Agénor, 2017). Problem nije količina obrazovanja, nego to što obrazovani pojedinci ne završavaju u djelatnostima u kojima bi njihov doprinos produktivnosti bio najveći. Znakovito je da su dvije zemlje s najvećim doprinosom ljudskog kapitala u EU upravo Hrvatska i Portugal. Za politiku obrazovanja to znači da mjere usmjerene na povećanje obuhvata imaju ograničen dodatni prinos u odnosu na mjere usmjerene na povećanje kvalitete obrazovanja te na zadržavanje i usmjeravanje već obrazovanih.

## 4.4. Utjecaj isplata iz EU fondova na TFP i konvergencijski kapacitet

Naposljetku, postavlja se pitanje uloge europskih strukturnih fondova u konvergenciji i konvergencijski kapacitet. U poglavlju 2.3. prikazano je da adekvatna kombinacija isplata iz EU fondova i kvalitete institucija dovodi do konvergencije na uzorku svih zemalja EU. U ovome poglavlju ćemo se neformalno dotaknuti pitanja kako isplate iz EU fondova utječu na konvergencijski kapacitet i ukupnu faktorsku produktivnost, prateći time strategiju 3i. Analiza prikazuje jednostavnu vezu između TFP-a (ili

konvergencijskog kapaciteta) i isplata iz EU fondova korištenjem grafikona rasipanja.

Pozitivna veza isplata iz EU fondova i TFP-a bi značila da se sredstva iz EU fondova pretaču u produktivnost i inovacije koje potom utječu na tekući i budući gospodarski rast. Sredstva iz EU fondova tada bi bila dobro iskorištena. Negativna veza značila bi da se sredstva iz EU fondova ulažu u druge faktore rasta, poput rada, kapitala ili ljudskog kapitala. U tom slučaju potencijal dugoročnog rasta bi bio ograničen. Stoga bi se moglo reći da sredstva nisu adekvatno iskorištena. Naposljetku, nulta veza između isplata iz EU fondova i TFP-a značila bi da poveznica nije jasna.

Prije same analize, potrebno je istaknuti nekoliko ograničenja. Prvo, nisu svi EU fondovi usmjereni na gospodarski rast niti na rast TFP-a. Najbolji primjeri takvih programa su fondovi Garancija za mlade, Europski socijalni fond[5] ili Fond europske pomoći za najpotrebitije. Najbliži je tom cilju Europski fond za regionalni razvoj, premda ni kod tog fonda nisu sva sredstva izravno povezana s rastom BDP-a niti TFP-a. U radu promatramo sve fondove agregatno, ali rezultati su robusni kada se u analizi promatra samo udio sredstava iz Europskog fonda za regionalni razvoj. Drugo, prava kauzalna analiza za Hrvatsku i Portugal trebala bi uzeti u obzir kontrolne varijable, dulje razdoblje i sofisticiranije metode utvrđivanja kauzalnosti. Međutim, u ovome radu se neformalno promatra povezanost korištenjem jednostavnih grafikona rasipanja. Treće, analiza je ograničena na razdoblje od 2007. do 2022. za Hrvatsku i od 2000. do 2022. za Portugal, što je prilično kratko razdoblje, ali je uvjetovano dostupnošću podataka.

[5] Garancija za mlade i Europski socijalni fond nisu usmjereni na gospodarski rast ili rast TFP-a, ali su usmjereni na izgradnju ljudskog kapitala. S obzirom na to da ljudski kapital prema strategiji 3i spada u infuziju te da čini polovicu konvergencijske košarice u slučaju AMECO baze podataka, radi jednostavnosti promatramo sve fondove agregatno.

## Slika 6. Povezanost TFP-a i isplata iz EU fondova

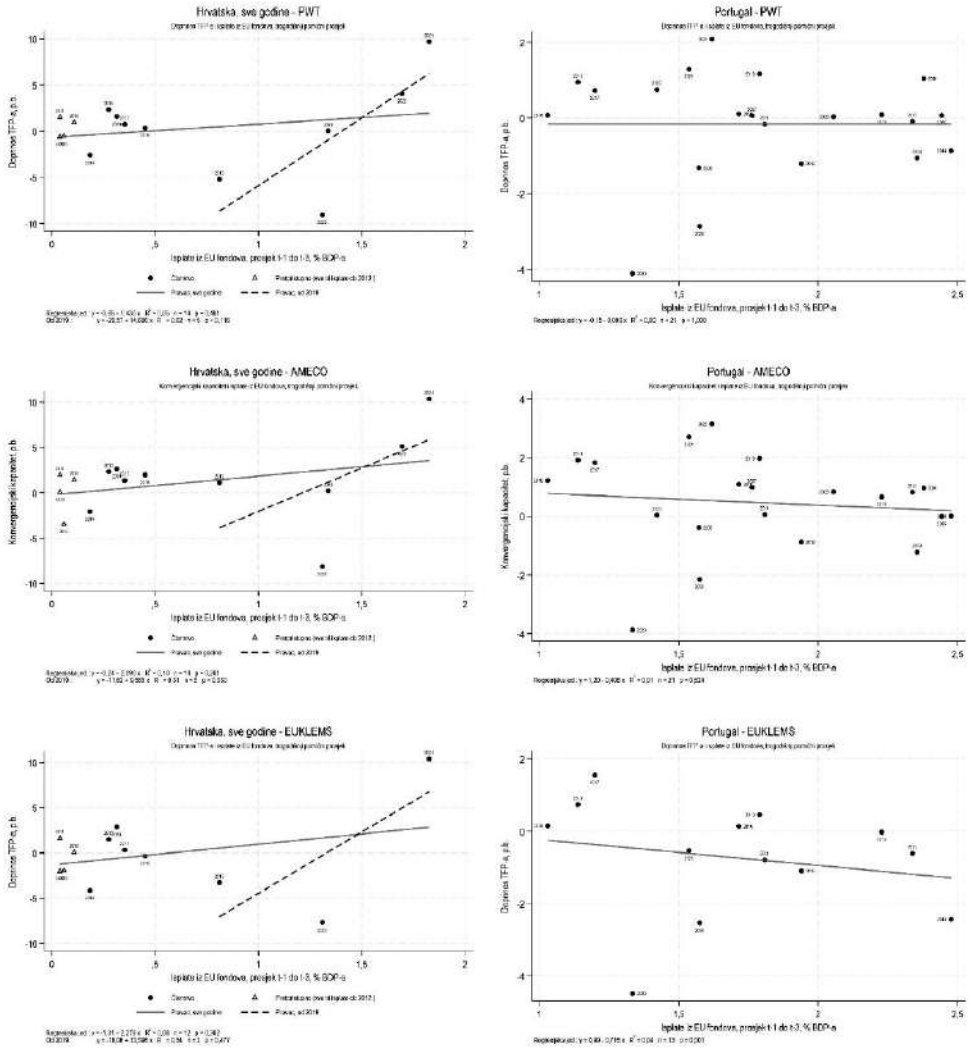


Izvor: Penn World Table 11.0, AMECO (proljeće 2026.) i EU KLEMS 2023 (D2.3.1); izračun autora.

Neformalna analiza pomoću grafikona rasipanja prikazana je na Slici 6. Prvi redak prikazuje rezultate za Hrvatsku za sve tri baze, dok drugi redak prikazuje rezultate za Portugal. Rezultati za AMECO bazu prikazuju

konvergencijski kapacitet umjesto TFP-a. Puna narančasta linija prikazuje smjer veze za sve promatrane godine u slučaju obiju zemalja. Iscrtkana zelena linija za Hrvatsku prikazuje vezu za razdoblje od 2019. godine do zadnje dostupne godine (2022. za PWT i AMECO baze te 2021. za EU KLEMS bazu). Pretpristupne godine za Hrvatsku, od 2007. do 2012. godine, posebno su prikazane trokutićima. Isplate iz EU fondova prikazane su s vremenskim pomakom od jedne godine te predstavljaju trogodišnje prosjeke. Ispod svakog grafikona je prikazana regresijska jednadžba koja opisuje nacrtani pravac zajedno s R-kvadratnom vrijednosti ($R^2$), brojem promatranja ($n$) i p-vrijednosti koeficijenta uz nagib regresijskog pravca.

Glavni zaključak je da ni u slučaju Hrvatske ni u slučaju Portugala nema statistički značajne veze između TFP-a i isplata iz EU fondova. U svih šest promatranih slučajeva, p-vrijednost je veća od standardnih razina značajnosti. Stoga se formalno može zaključiti kako veza između promatranih varijabli nije jasna.

Međutim, u Hrvatskoj je nagib pravca za sve tri baze blago pozitivan, što upućuje na moguću pozitivnu vezu koju podaci, međutim, ne potvrđuju na standardnim razinama značajnosti. To se osobito odnosi na zadnje promatrano razdoblje od 2019. do 2022. godine, u kojem je pozitivan nagib još očitiji. S druge strane, za Portugal je vidljiv blago negativan nagib u sva tri slučaja. Zbog visoke raspršenosti i malog broja promatranja, teško je utvrditi čvrstu vezu, ali okvirno se može zaključiti kako se sredstva iz EU fondova drukčije koriste u slučaju Hrvatske u odnosu na Portugal, što je dodatna potvrda različitosti dviju zemalja koja je uočena kod računovodstva rasta.

Drugim riječima, za Hrvatsku je moguće da je jedan dio sredstava iz EU fondova ipak pronašao svoj put do djelatnosti koje povećavaju produktivnost i TFP te pogoduju održivom ekonomskom rastu u skladu sa strategijom 3i.

Rezultati su robusni kada se ukupna sredstva iz EU fondova zamijene sredstvima iz Europskog fonda za regionalni razvoj te kada se promatra jednogodišnje razdoblje umjesto trogodišnjeg prosjeka.

# 5. ZAKLJUČAK

## 5.1. Temeljni zaključci rada

U radu se ispituje postoji li realna konvergencija BDP-a per capita među zemljama članicama Europske unije te kakav je sastav rasta koji tu konvergenciju proizvodi. Polazna je hipoteza da brzina konvergencije sama po sebi ne govori je li konvergencija održiva, jer ista stopa rasta može nastati akumulacijom rada i kapitala ili rastom produktivnosti. Tu razliku analiziramo razlikovanjem apsorpcijskog i konvergencijskog kapaciteta i mjerimo je računovodstvom rasta provedenim usporedno na tri baze podataka.

Rezultati potvrđuju postojanje uvjetne konvergencije među članicama EU, pri čemu su sredstva iz europskih fondova i kvaliteta institucija usko povezani s njezinom brzinom. Sredstva mogu kratkoročno supstituirati kvalitetu institucija, ali institucije određuju gornju granicu konvergencije i time njezinu održivost. Agregatne dokaze o postojanju „zida“ na razini od 80 posto prosjeka BDP-a per capita EU nismo pronašli. Izostanak zida, međutim, ne znači izostanak zamke, jer brzina konvergencije ne govori ništa o strukturi rasta. Indikativno je da su doprinosi ljudskog kapitala i produktivnosti statistički značajni samo iznad tog praga, dok ispod njega značajne ostaju samo investicije.

Računovodstvo rasta potvrđuje da Portugal ima obilježja zemlje u razvojnoj zamci (zamci srednjeg dohotka). Doprinos ukupne faktorske produktivnosti rastu iznosi minus 0,25 postotnih bodova u razdoblju od 1996. do 2023. godine, dok je doprinos ljudskog kapitala s 0,51 postotnim bodom drugi najveći u EU, iza Hrvatske. Portugal je stoga došao do faze infuzije, ali nije napravio prijelaz u fazu inovacije prema strategiji 3i.

Hrvatski konvergencijski kapacitet u prosjeku razdoblja iznosi 1,01 postotni bod, što je unutar raspona skupine novih članica i ispod vrijednosti baltičkih zemalja, Slovenije, Slovačke, Poljske, Rumunjske, Mađarske i Cipra. Unutar cijelog promatranog razdoblja, iznimno je snažna epizoda između 2021. i 2023. godine kada dominira udio TFP-a u ekonomskom rastu. Od 2024. sastav rasta mijenja se u nepovoljnom smjeru, jer prevladavaju doprinosi rada i fizičkog kapitala, a prema projekcijama konvergencijska košarica u 2026. i 2027. pada na nulu. Riječ je dakle o riziku da razdoblje najvećeg priljeva europskih sredstava prođe bez trajne promjene strukture rasta. Stoga, važno

je adekvatno alocirati dostupna sredstva u djelatnosti znanosti te istraživanja i razvoja kako bi se struktura rasta usmjerila na rast produktivnosti.

Nadalje, Hrvatska ima najveći doprinos ljudskog kapitala rastu u cijeloj Uniji uz osrednji doprinos produktivnosti, a korelacija tih dviju veličina među članicama praktički ne postoji. To upućuje na pogrešnu alokaciju, a ne na nedostatak ljudskog kapitala.

Veza između sredstava iz EU fondova i ukupne faktorske produktivnosti nije čvrsta u slučaju Hrvatske i Portugala. Međutim, rezultati sugeriraju kako je regresijski pravac u slučaju Hrvatske blago pozitivnog nagiba, uz osobito snažan pozitivan nagib za razdoblje od 2019. do 2022. godine. S druge strane, regresijski pravac u slučaju Portugala je blago negativnog nagiba, što sugerira dodatne razlike među zemljama. Stoga, moguće je da je u Hrvatskoj dio sredstava iz EU fondova našao put do djelatnosti koje povećavaju produktivnost i konvergencijski kapacitet.

## 5.2. Preporuke za ekonomsku politiku

Najizravnija implikacija ove analize odnosi se na način na koji se u Hrvatskoj (ali i EU) mjeri uspjeh kohezijske politike. Javna rasprava, mediji, izvještavanje nadležnih tijela i politička ocjena uspješnosti gotovo isključivo počivaju na stopi iskorištenosti, dakle na udjelu ugovorenih i isplaćenih sredstava u dodijeljenoj omotnici. Rezultati ovog rada pokazuju da je to nepotpuno mjerilo, a u određenim okolnostima i pogrešno. Apsorpcijski i konvergencijski kapacitet dvije su različite sposobnosti koje nisu snažno povezane. Becker, Egger i von Ehrlich (2013) pokazuju da učinak transfera presudno ovisi o ljudskom kapitalu i kvaliteti institucija regije primatelja, pa se visoka stopa iskorištenosti može ostvariti i uz zanemariv doprinos rastu. Naši rezultati taj nalaz potvrđuju na razini strukture rasta: Hrvatska i Portugal imali su podjednak pristup sredstvima EU fondova, ali je odredište tih sredstava bilo drugačije. U razdoblju provedbe NPOO-a, Hrvatska je ostvarila najveći priljev europskih sredstava u svojoj povijesti, ali konvergencijska košarica nije značajno pridonijela rastu.

Predlažemo da se uz stopu iskorištenosti EU sredstava uvede i redovito prati konvergencijska košarica, definirana kao zbroj doprinosa ljudskog kapitala i ukupne faktorske produktivnosti rastu bruto domaćeg proizvoda. Riječ je o pokazatelju koji se izračunava iz javno dostupnih podataka nacionalnih računa, metodologijom prikazanom u ovom radu, i koji se može objavljivati

godišnje uz izvješća o provedbi operativnih programa. Takav pokazatelj odgovara na pitanje koje stopa iskorištenosti ne može odgovoriti: pretvaraju li se povučena sredstva u sposobnost gospodarstva da raste i nakon što priljev prestane. Pri tumačenju treba imati na umu da je ukupna faktorska produktivnost rezidual koji upija i promjene u iskorištenosti kapaciteta, pa pokazatelj treba promatrati u višegodišnjem prosjeku i ciklički prilagođeno, a ne kao godišnju ocjenu.

Praktična je posljedica takve promjene mjerila da se prioritet u odabiru projekata pomiče s brzine ugovaranja na očekivani učinak na produktivnost. U sadašnjem sustavu poticaji upravljačkih tijela usmjereni su prema izbjegavanju gubitka sredstava, što pogoduje projektima koji se brzo provode i lako opravdavaju, a to su tipično infrastrukturni i građevinski projekti usmjereni na akumulaciju fizičkog kapitala. Upravo ta vrsta projekata najviše doprinosi apsorpcijskom, a najmanje konvergencijskom kapacitetu.

Na europskoj razini rezultati upućuju na ograničenje sadašnjih kriterija prihvatljivosti. Pragovi od 75 posto prosjeka za status slabije razvijene regije i 90 posto bruto nacionalnog dohotka za korištenje Kohezijskog fonda definirani su isključivo razinom dohotka. Naši rezultati pokazuju da se pokretači rasta mijenjaju s razvojnim statusom: ljudski kapital i ukupna faktorska produktivnost statistički su značajni samo u poduzorku zemalja iznad 80 posto prosjeka Unije, dok ispod tog praga značajne ostaju samo investicije. Iz logike strategije 3i slijedi da bi se s razvojnim statusom trebala mijenjati i struktura instrumenata, a ne samo intenzitet potpore.

Konkretno, zemljama i regijama koje su prešle prag od 75 posto prosjeka trebalo bi propisati veći minimalni udio alokacije usmjeren na instrumente infuzije i inovacije, dakle na istraživanje i razvoj, prijenos tehnologije, digitalnu infrastrukturu i suradnju s poduzećima na tehnološkoj granici, uz odgovarajuće manji udio namijenjen osnovnoj infrastrukturi. Time bi se kriterij prihvatljivosti vezao uz razvojnu fazu, a ne samo uz razinu dohotka. Dodatno, praćenje uspješnosti kohezijske politike na razini Unije trebalo bi uz relativni BDP per capita uključivati i dekompoziciju rasta, jer razvojna zamka nije prekid u razini dohotka nego promjena u strukturi rasta, a taj se prekid u podacima u razinama ne vidi.

Nalaz da Hrvatska ima najveći doprinos ljudskog kapitala rastu u Uniji uz osrednji doprinos produktivnosti mijenja prioritete obrazovne i inovacijske politike. Ograničenje nije u razini obrazovanosti radne snage, nego u tome gdje ta radna snaga završava. Literatura o zamci srednjeg dohotka taj

mehanizam opisuje kao pogrešnu distribuciju ljudskog kapitala, pri čemu sposobni pojedinci biraju sektore s višim ili sigurnijim plaćama umjesto rizičnih poduzetničkih i inovacijskih djelatnosti, a razlozi su slaba zaštita intelektualnog vlasništva, neizvjesno izvršavanje ugovora i ograničen pristup financiranju putem rizičnog kapitala (Agénor i Canuto, 2015; Agénor, 2017).

Prioritet stoga nisu mjere koje dodatno povećavaju obuhvat tercijarnog obrazovanja, nego mjere koje podižu očekivani prinos na inovacijsku aktivnost i kvalitetu obrazovanja. To uključuje pravnu sigurnost i brzinu rješavanja trgovačkih sporova, funkcionalan okvir za stečaj i izlazak poduzeća bez kojega nema realokacije resursa, uklanjanje prepreka ulasku novih poduzeća, razvoj tržišta rizičnog kapitala te uvjete koji smanjuju odljev visokoobrazovane radne snage. Zajednički je nazivnik tih mjera sprječavanje politika koje štite postojeće stanje, što je u schumpeterovskom okviru glavni mehanizam blokade prijelaza iz faze imitacije u fazu inovacije (Acemoglu, Aghion i Zilibotti, 2006).

## 5.3. Ograničenja i preporuke za buduća istraživanja

Rezultate treba čitati uz nekoliko ograničenja. Ukupna faktorska produktivnost je rezidual, pa uz tehnološki napredak upija i pogrešku mjerenja, promjene u iskorištenosti kapaciteta, realokaciju resursa među sektorima, ali i sve ostale faktore koji nisu mjereni, poput kvalitete institucija. Detaljna analiza provedena je za dvije zemlje, što ne dopušta poopćavanje, premda su prosjeci za svih 27 članica prikazani u Prilogu A. Analiza povezanosti europskih sredstava i produktivnosti počiva na malom broju opažanja i neformalne je prirode, pa je ne treba tumačiti uzročno. Za Hrvatsku i većinu novijih članica puna podjela kapitala po vrstama imovine dostupna je tek od 2009. godine, što ograničava analizu sastava rasta na kraće razdoblje. Prirodni nastavak ovog istraživanja jest formalna panel analiza povezanosti europskih sredstava, kvalitete institucija i ukupne faktorske produktivnosti na uzorku svih zemalja članica, te sektorska dekompozicija kojom bi se izravno testirala hipoteza o preusmjeravanju kapitala prema nerazmjenjivim djelatnostima.

# PRILOG A. Dodatni rezultati

## Tablica A1. Računovodstvo rasta, prosjeci po razdobljima za Hrvatsku i Portugal – tri baze

| Zemlja | Baza | Razdoblje | Rast BDP-a | Rad | Kapital | Ljud. kap. | TFP | Konv. | Apsorp. |
|---|---|---|---|---|---|---|---|---|---|
| Hrvatska | PWT | 1996-2007 | 4.04 | 0.53 | 1.57 | 0.60 | 1.34 | 1.94 | 2.10 |
| | | 2008-2013 | -1.49 | -1.48 | 0.87 | 0.68 | -1.57 | -0.88 | -0.61 |
| | | 2014-2018 | 2.25 | 0.31 | 0.66 | 0.78 | 0.50 | 1.28 | 0.97 |
| | | 2020-2023 | 3.38 | 0.34 | 0.98 | 0.86 | 1.20 | 2.05 | 1.32 |
| | | 1996-2023 | 2.41 | 0.24 | 1.16 | 0.70 | 0.31 | 1.01 | 1.40 |
| | EUKLEMS | 1996-2007 | 4.08 | 0.60 | 2.11 | | | 1.38 | 2.70 |
| | | 2008-2013 | -1.56 | -1.64 | 1.18 | | | -1.09 | -0.46 |
| | | 2014-2018 | 2.05 | 0.49 | 0.99 | 0.53 | 0.04 | 0.57 | 1.48 |
| | | 2020-2021 | 1.75 | -0.35 | 0.67 | 0.07 | 1.36 | 1.43 | 0.32 |
| | | 1996-2021 | 2.18 | 0.18 | 1.53 | | | 0.47 | 1.71 |
| | AMECO | 1996-2007 | 4.04 | 0.51 | 1.18 | | | 2.35 | 1.69 |
| | | 2008-2013 | -1.49 | -0.82 | 0.92 | | | -1.59 | 0.10 |
| | | 2014-2019 | 2.38 | 0.47 | 0.67 | | | 1.24 | 1.15 |
| | | 2020-2023 | 3.49 | 0.34 | 1.25 | | | 1.89 | 1.59 |
| | | 1996-2025 | 2.50 | 0.28 | 1.11 | | | 1.10 | 1.39 |
| | | 2022-2025 | 4.46 | 1.19 | 2.08 | | | 1.19 | 3.27 |
| | | 2026-2027* | 2.54 | 0.50 | 2.08 | | | -0.04 | 2.58 |
| Portugal | PWT | 1996-2007 | 2.37 | 0.61 | 1.55 | 0.51 | -0.31 | 0.21 | 2.16 |
| | | 2008-2013 | -1.33 | -1.58 | 0.40 | 0.56 | -0.72 | -0.15 | -1.18 |
| | | 2014-2018 | 2.09 | 1.35 | 0.35 | 0.40 | -0.01 | 0.39 | 1.70 |
| | | 2020-2023 | 1.52 | 0.40 | 0.54 | 0.58 | 0.00 | 0.59 | 0.94 |
| | | 1996-2023 | 1.42 | 0.24 | 0.91 | 0.51 | -0.25 | 0.26 | 1.16 |
| | EUKLEMS | 2001-2007 | 1.22 | -0.05 | 0.80 | | | 0.47 | 0.75 |
| | | 2008-2013 | -0.90 | -1.59 | 0.20 | | | 0.49 | -1.39 |
| | | 2014-2018 | 1.86 | 1.18 | 0.06 | 0.86 | -0.24 | 0.62 | 1.24 |
| | | 2020-2021 | -1.40 | -1.40 | 0.35 | 2.17 | -2.51 | -0.34 | -1.05 |
| | | 2001-2021 | 0.59 | -0.30 | 0.39 | | | 0.50 | 0.09 |

| Zemlja | Baza | Razdoblje | Rast BDP-a | Rad | Kapital | Ljud. kap. | TFP | Konv. | Apsorp. |
|---|---|---|---|---|---|---|---|---|---|
| Portugal | AMECO | 1996-2007 | 2.37 | 0.57 | 1.40 | | | 0.40 | 1.97 |
| | | 2008-2013 | -1.33 | -1.43 | 0.22 | | | -0.12 | -1.21 |
| | | 2014-2018 | 2.09 | 1.20 | -0.10 | | | 1.00 | 1.10 |
| | | 2020-2023 | 1.66 | 0.94 | 0.22 | | | 0.51 | 1.16 |
| | | 1996-2025 | 1.48 | 0.34 | 0.65 | | | 0.49 | 0.99 |
| | | 2022-2025 | 3.46 | 1.88 | 0.36 | | | 1.23 | 2.24 |
| | | 2026-2027* | 1.74 | 0.68 | 0.49 | | | 0.57 | 1.17 |

Napomena: Sve vrijednosti u postotnim bodovima. Prognozirane godine su zasebno prikazane u redcima označenim *. Prazne ćelije u stupcima Ljud. kap. i TFP znače da ta podjela za danu bazu i razdoblje ne postoji: AMECO nema indeks kvalitete rada, a u EU KLEMS-u za Hrvatsku i većinu novijih članica te serije počinju tek 2009. U tim je slučajevima njihov zbroj prikazan u stupcu Konv., koji se računa oduzimanjem i zato postoji za cijelo razdoblje. U PWT i EU KLEMS bazama podataka postoji strukturni prekid u seriji sati rada za 2019. godinu, pa je ta godina izbačena iz prosjeka podrazdoblja, a zadržana je u ukupnom prosjeku. U AMECO bazi takav prekid ne postoji, pa je radi potpunosti 2019. godina uključena u prosjek.

Izvor: Penn World Table 11.0, AMECO (proljeće 2026.) i EU KLEMS 2023 (D2.3.1); izračun autora.

## Tablica A2. Računovodstvo rasta, prosjeci 1996. – 2023. za svih 27 članica EU, PWT baza

| Zemlja | n | Rast BDP-a | Rad | Kapital | Ljud. kap. | TFP | Konv. | Apsorp. |
|---|---|---|---|---|---|---|---|---|
| Austrija | 28 | 1.64 | 0.29 | 1.00 | 0.27 | 0.08 | 0.36 | 1.29 |
| Belgija | 28 | 1.79 | 0.61 | 1.07 | 0.21 | -0.10 | 0.11 | 1.68 |
| Bugarska | 28 | 2.24 | -0.10 | 3.65 | 0.26 | -1.56 | -1.31 | 3.54 |
| Cipar | 28 | 3.08 | 0.86 | 1.12 | 0.41 | 0.68 | 1.10 | 1.98 |
| Danska | 28 | 1.70 | 0.38 | 0.94 | 0.31 | 0.07 | 0.38 | 1.32 |
| Estonija | 28 | 3.52 | -0.28 | 1.76 | 0.36 | 1.68 | 2.04 | 1.48 |
| Finska | 28 | 1.83 | 0.37 | 0.90 | 0.34 | 0.20 | 0.55 | 1.28 |
| Francuska | 28 | 1.51 | 0.42 | 0.79 | 0.35 | -0.05 | 0.30 | 1.21 |
| Grčka | 28 | 0.97 | 0.17 | 0.68 | 0.41 | -0.28 | 0.13 | 0.85 |
| Hrvatska | 28 | 2.41 | 0.24 | 1.16 | 0.70 | 0.31 | 1.01 | 1.40 |
| Irska | 28 | 5.53 | 0.51 | 3.43 | 0.25 | 1.34 | 1.58 | 3.95 |
| Italija | 28 | 0.66 | 0.20 | 0.82 | 0.39 | -0.75 | -0.36 | 1.02 |
| Latvija | 28 | 3.56 | -0.36 | 1.20 | 0.33 | 2.39 | 2.71 | 0.84 |
| Litva | 28 | 3.93 | 0.07 | 1.67 | 0.40 | 1.79 | 2.19 | 1.73 |
| Luksemburg | 28 | 3.00 | 1.25 | 1.94 | 0.36 | -0.56 | -0.20 | 3.20 |
| Malta | 28 | 4.44 | 1.03 | 2.41 | 0.50 | 0.51 | 1.01 | 3.44 |
| Mađarska | 28 | 2.42 | 0.10 | 1.15 | 0.44 | 0.74 | 1.17 | 1.25 |
| Nizozemska | 28 | 2.00 | 0.65 | 0.96 | 0.25 | 0.13 | 0.39 | 1.61 |
| Njemačka | 28 | 1.23 | 0.10 | 0.65 | 0.13 | 0.36 | 0.49 | 0.75 |
| Poljska | 28 | 3.82 | 0.33 | 2.00 | 0.40 | 1.09 | 1.49 | 2.33 |
| Portugal | 28 | 1.42 | 0.24 | 0.91 | 0.51 | -0.25 | 0.26 | 1.16 |
| Rumunjska | 28 | 2.94 | -0.66 | 2.12 | 0.28 | 1.21 | 1.49 | 1.45 |
| Slovačka | 28 | 3.29 | 0.02 | 1.37 | 0.34 | 1.55 | 1.90 | 1.39 |
| Slovenija | 28 | 2.59 | 0.16 | 1.04 | 0.32 | 1.07 | 1.38 | 1.20 |
| Češka | 28 | 2.22 | 0.03 | 1.26 | 0.21 | 0.72 | 0.93 | 1.29 |
| Španjolska | 28 | 1.94 | 0.82 | 1.08 | 0.41 | -0.37 | 0.04 | 1.90 |
| Švedska | 28 | 2.20 | 0.50 | 0.97 | 0.23 | 0.51 | 0.74 | 1.47 |

Napomena: Sve vrijednosti u postotnim bodovima.

Izvor: Penn World Table 11.0, AMECO (proljeće 2026.) i EU KLEMS 2023 (D2.3.1); izračun autora.

## LITERATURA

Acemoglu, D., Aghion, P. i Zilibotti, F. (2006). Distance to Frontier, Selection, and Economic Growth. *Journal of the European Economic Association*, 4(1), 37–74.

Agénor, P.-R. (2017). Caught in the Middle? The Economics of Middle-Income Traps. *Journal of Economic Surveys*, 31(3), 771–791. https://doi.org/10.1111/joes.12175

Agénor, P.-R. i Aizenman, J. (2010). Aid volatility and poverty traps. *Journal of Development Economics*, 91(1), 1–7.

Agénor, P.-R. i Canuto, O. (2015). Middle-income growth traps. *Research in Economics*, 69(4), 641–660.

Aghion, P. i Bircan, C. (2017). The Middle-Income Trap from a Schumpeterian Perspective. *ADB Economics Working Paper Series* No. 521. Manila: Asian Development Bank.

Aghion, P. i Howitt, P. (1992). A Model of Growth through Creative Destruction. *Econometrica*, 60(2), 323–351.

Akcigit, U. i Kerr, W. R. (2018). Growth through Heterogeneous Innovations. *Journal of Political Economy*, 126(4), 1374–1443.

Arčabić, V. (2025). Priča o dvije inflacije u Hrvatskoj: uloga domaćih i inozemnih šokova. *EFZG working paper series*, *2025*(04), 1-22.

Arellano, M. i Bond, S. (1991). Some tests of specification for panel data: Monte Carlo evidence and an application to employment equations. *The Review of Economic Studies*, 58(2), 277–297.

Arellano, M. i Bover, O. (1995). Another look at the instrumental variable estimation of error-components models. *Journal of Econometrics*, 68(1), 29–51.

Athukorala, P.-C. i Woo, W. T. (2011). Malaysia in the middle-income trap. Crawford School of Public Policy, Australian National University, Canberra.

Azariadis, C. i Stachurski, J. (2005). Poverty traps. *Handbook of Economic Growth*, 1, 295–384.

Becker, S. O., Egger, P. H. i von Ehrlich, M. (2010). Going NUTS: The effect of EU Structural Funds on regional performance. *Journal of Public Economics*, 94(9–10), 578–590.

Becker, S. O., Egger, P. H. i von Ehrlich, M. (2012). Too much of a good thing? On the growth effects of the EU's regional policy. *European Economic Review*, 56(4), 648–668.

Becker, S. O., Egger, P. H. i von Ehrlich, M. (2013). Absorptive Capacity and the Growth and Investment Effects of Regional Transfers: A Regression Discontinuity Design with Heterogeneous Treatment Effects. *American Economic Journal: Economic Policy*, 5(4), 29–77.

Becker, S. O., Egger, P. H. i von Ehrlich, M. (2018). Effects of EU regional policy: 1989–2013. *Regional Science and Urban Economics*, 69, 143–152.

Becker, W., Norlen, H., Dijkstra, L. i Athanasoglou, S. (2020). Wrapping up the Europe 2020 strategy: A multidimensional indicator analysis. *Environmental and Sustainability Indicators*, 8, 100075.

Blanchard, O. i Portugal, P. (2017) „Boom, slump, sudden stops, recovery, and policy options. Portugal and the Euro", *Portuguese Economic Journal*, 16(3), str. 149–168.

Blundell, R. i Bond, S. (1998). Initial conditions and moment restrictions in dynamic panel data models. *Journal of Econometrics*, 87(1), 115–143.

Bontadini, F., Corrado, C., Haskel, J., Iommi, M. i Jona-Lasinio, C. (2023). EUKLEMS & INTANProd: Industry Productivity Accounts with Intangibles. Methodological description. Luiss Lab of European Economics, Rim.

Brambor, T., Clark, W. R. i Golder, M. (2006). Understanding Interaction Models: Improving Empirical Analyses. *Political Analysis*, 14(1), 63–82.

Butkus, M., Mačiulytė-Šniukienė, A., Macaitienė, R. i Matuzevičiūtė, K. (2021). A New Approach to Examine Non-Linear and Mediated Growth and Convergence Outcomes of Cohesion Policy. *Economies*, 9, 1–28.

Cerqua, A. i Pellegrini, G. (2023). I will survive! The impact of place-based policies when public transfers fade out. *Regional Studies*, *57*(8), 1605–1618.

Crescenzi, R. i Giua, M. (2020). One or many Cohesion Policies of the European Union? On the differential economic impacts of Cohesion Policy across member states. *Regional Studies*, 54(1), 10–20. https://doi.org/10.1080/00343404.2019.1665174

Croxford, G. J., Wise, M. i Chalkley, B. S. (1987). The Reform of the European Regional Development Fund: A Preliminary Assessment. *Journal of Common Market Studies*, 26(1), 25–38.

Diaz del Hoyo, J. L. i sur. (2017). Real convergence in the euro area: A long-term perspective. *ECB Occasional Paper No. 203*. Frankfurt na Majni: Europska centralna banka. https://doi.org/10.2866/121513

Diemer, A. i sur. (2022). The Regional Development Trap in Europe. *Economic Geography*, 98(5), 487–509. https://doi.org/10.1080/00130095.2022.2080655

Diewert, W. E. (1976). Exact and Superlative Index Numbers. *Journal of Econometrics*, 4(2), 115–145.

Durlauf, S. N. i Johnson, P. A. (1995). Multiple regimes and cross-country growth behaviour. *Journal of Applied Econometrics*, 10(4), 365–384. https://doi.org/10.1002/jae.3950100404

Durlauf, S. N., Johnson, P. A. i Temple, J. R. W. (2005). Growth econometrics. U: P. Aghion i S. Durlauf (ur.), *Handbook of Economic Growth* (str. 555–677). Amsterdam: Elsevier.

Eichengreen, B., Park, D. i Shin, K. (2012). When Fast-Growing Economies Slow Down: International Evidence and Implications for China. *Asian Economic Papers*, 11(1), 42–87. https://doi.org/10.1162/ASEP_a_00118

Eichengreen, B., Park, D. i Shin, K. (2014). Growth slowdowns redux. *Japan and the World Economy*, 32, 65–84. https://doi.org/10.1016/j.japwor.2014.07.003

Europska komisija (2024). *Ninth report on economic, social and territorial cohesion*. Publications Office of the European Union, Luxembourg.

Europska komisija (2026). *AMECO: Annual Macro-Economic Database of the European Commission*, proljetna prognoza 2026. Directorate-General for Economic and Financial Affairs, Bruxelles.

Europska komisija, Directorate-General for Regional and Urban Policy, LSE Consulting, Iammarino, S., Rodríguez-Pose, A., Storper, M. i sur. (2020). *Falling into the middle-income trap? A study on the risks for EU regions to be caught in a middle-income trap: Final report*. Luxembourg: Publications Office of the European Union. https://data.europa.eu/doi/10.2776/02363

Fagerberg, J. i Verspagen, B. (1996). Heading for Divergence? Regional Growth in Europe Reconsidered. *JCMS: Journal of Common Market Studies*, 34(3), 431–448. https://doi.org/10.1111/j.1468-5965.1996.tb00580.x

Feenstra, R. C., Inklaar, R. i Timmer, M. P. (2015). The Next Generation of the Penn World Table. *American Economic Review*, 105(10), 3150–3182.

Gill, I. S., Kharas, H. J. i Bhattasali, D. (2007). *An East Asian Renaissance: Ideas for Economic Growth*. Washington, DC: World Bank.

Iammarino, S., Rodríguez-Pose, A. i Storper, M. (2019). Regional inequality in Europe: evidence, theory and policy implications. *Journal of Economic Geography*, 19(2), 273–298.

Im, F. G. i Rosenblatt, D. (2015). Middle-Income Traps: A Conceptual and Empirical Survey. *Journal of International Commerce, Economics and Policy*, 6(3), 1550013. https://doi.org/10.1142/S1793993315500131

Jorgenson, D. W. i Griliches, Z. (1967). The Explanation of Productivity Change. *The Review of Economic Studies*, 34(3), 249–283.

Kasprzyk, B. i Wojnar, J. (2021). An Evaluation of the Implementation of the Europe 2020 Strategy. *Economic and Regional Studies*, 14(2).

Mankiw, N. G., Romer, D. i Weil, D. N. (1992). A Contribution to the Empirics of Economic Growth. *The Quarterly Journal of Economics*, 107(2), 407–437.

Markušić, G. (2026). Utjecaj izdataka iz Europskih strukturnih fondova i kvalitete institucija na ekonomski rast i konvergenciju regija Europske unije. *Doktorska disertacija*. Ekonomski fakultet – Zagreb, Sveučilište u Zagrebu.

Nahuis, R. i de Mooji, R. (2001). Cohesion Policy in the EU: Going beyond Fiscal Transfers? *De Economist*, 149(3), 365–367.

Pellegrini, G. i sur. (2013). Measuring the effects of European Regional Policy on economic growth: A regression discontinuity approach. *Papers in Regional Science*, 92(1), 217–234.

Pritchett, L. i Summers, L. H. (2014). Asiaphoria Meets Regression to the Mean. *NBER Working Paper No. 20573*. Cambridge, MA: National Bureau of Economic Research. https://doi.org/10.3386/w20573

Raguž Krištić, I., Družić, I., & Tica, J. (2016). Impact of the transition on the total factor productivity in Croatia. *Zbornik radova Ekonomskog fakulteta u Rijeci: časopis za ekonomsku teoriju i praksu*, *34*(2), 271-308.

Reis, R. (2013) *The Portuguese slump and crash and the euro crisis*. National Bureau of Economic Research. Dostupno na: https://www.nber.org/papers/w19288 (Pristupljeno: 29. lipanj 2026.).

Rodríguez-Pose, A. i Garcilazo, E. (2015). Quality of Government and the Returns of Investment: Examining the Impact of Cohesion Expenditure in European Regions. *Regional Studies*, 49(8), 1274–1290. https://doi.org/10.1080/00343404.2015.1007933

Schumpeter, J. A. (1942). *Capitalism, Socialism and Democracy*. New York: Harper & Brothers.

Solow, R. M. (1956). A Contribution to the Theory of Economic Growth. *The Quarterly Journal of Economics*, 70(1), 65–94.

Solow, R. M. (1957). Technical Change and the Aggregate Production Function. *The Review of Economics and Statistics*, 39(3), 312–320.

Svjetska banka (2024). *World Development Report 2024: The Middle-Income Trap*. Washington, DC: World Bank.

Svjetska banka (2026). World Bank Country and Lending Groups. Preuzeto 6. rujna 2026. s https://datahelpdesk.worldbank.org/knowledgebase/articles/906519-world-bank-country-and-lending-groups.

Swan, T. W. (1956). Economic growth and capital accumulation. *Economic Record*, 32(2), 334–361.

Tica, J., Viljevac, V., & Matić, M. (2023). Employment rate and economic growth: The case of transition countries. *Zbornik radova Ekonomskog fakulteta u Rijeci: časopis za ekonomsku teoriju i praksu*, *41*(1), 9-39.

# CONVERGENCE ON CREDIT? ABSORPTION AND CONVERGENCE CAPACITY IN THE EU – THE CASE OF CROATIA AND PORTUGAL*

***Abstract***

*This paper examines whether there is convergence among EU member states and, more importantly, what composition of growth drives the convergence. The speed of convergence alone does not reveal whether convergence is sustainable in the long run, since economic growth may result either from accumulation of labor and capital or from productivity growth. We therefore propose distinguishing absorption capacity, measured as the sum of the contributions of labor and physical capital to growth, from convergence capacity, measured as the sum of the contributions of human capital and total factor productivity. We estimate a conditional convergence model for the 27 EU member states over the period from 2000 to 2025 and perform growth accounting for Croatia and Portugal based on three databases: Penn World Table 11.0, EU KLEMS and AMECO. The results confirm conditional convergence, with European funds closely related to its speed, while the quality of institutions determine its upper bound. We find no evidence of a convergence slowdown at the threshold of 80 % of average GDP per capita, but the contributions of human capital and productivity are statistically significant only above that threshold. Portugal completed the infusion phase but did not make the transition to the innovation phase, and it shows the characteristics of an economy in a middle-income trap. Croatia's convergence capacity is close to the EU average, but below the level of comparable new member states, with an exceptionally strong convergence episode between 2021 and 2023, whereas since 2024 the accumulation of labor and physical capital prevails. The relationship between European fund spending and productivity is not statistically significant, although Croatia shows a slightly positive relationship, unlike Portugal, where the relationship is slightly negative. It follows that the absorption rate of EU funds alone is not a sufficient measure of the success of cohesion policy; it needs to be complemented by data on convergence capacity.*

***Keywords:*** *convergence, cohesion policy, development trap, growth accounting, total factor productivity, absorption and convergence capacity, Croatia, Portugal.*

* This paper was funded by the European Union NextGenerationEU under Call IIP 581 2025.

JEL klasifikacija: C38, E44, E58, G01, R31
Izvorni znanstveni rad

# INDIKATOR NEUSKLAĐENOSTI CIJENA STAMBENIH NEKRETNINA S FUNDAMENTIMA ZA HRVATSKU (HPMI-HR): KONSTRUKCIJA, DEKOMPOZICIJA I VALIDACIJA

Nenad Bakić*

## SAŽETAK

Rad konstruira kompozitni indikator neusklađenosti cijena stambenih nekretnina s fundamentima (housing price misalignment indicator, HPMI) za Hrvatsku u dvije specifikacije te procjenjuje veličinu i strukturu odstupanja cijena od fundamenata početkom 2026. Sedam pod-indikatora potražne, ponudbene i sistemske perspektive (osnovna specifikacija, 2002Q1–2026Q1), odnosno devet (proširena specifikacija, 2012Q1–2026Q1), transformira se u jaz prema dugoročnoj referentnoj vrijednosti i agregira ponderima izvedenima iz faktorske analize, po metodologiji koju primjenjuju Bundesbank, Banka Slovenije, središnja banka Malte i Hrvatska narodna banka. Osnovna specifikacija pokazuje pozitivan jaz od 14,7% u 2026Q1, što upućuje na cijene oko 15% iznad razine koju podupiru fundamenti; raspon 18 varijanti iznosi +10,0% do +26,6%. Dekompozicija pokazuje da odstupanje danas nose realni cjenovni jaz (cijene/HICP) i visoke stambene investicije, a

* Nenad Bakić, CFA, SELECTIO (e-mail: nenad.bakic@selectio.hr).

ne dohodovna i kreditna komponenta kao 2007., što je relevantno za kalibraciju makrobonitetnih ograničenja (DSTI/LTV). Fundamentalna vrijednost nije opažljiva; uzorak pokriva oko jedan i pol ciklus; ne postoji domaća epizoda sloma za strogu evaluaciju svojstava ranog upozorenja; pokazatelj cijene/HICP ne razlikuje precijenjenost od konvergencije dohotka. Rad doprinosi postojećim analizama hrvatskoga stambenog tržišta, uključujući kompozitni pokazatelj Hrvatske narodne banke, usporedbom osnovne i proširene specifikacije kompozitnog pokazatelja, kvantifikacijom promjene strukture odstupanja između dvaju ciklusa te analizom osjetljivosti na podacima do prvog tromjesečja 2026. Postupak se oslanja isključivo na javne izvore; kôd i podaci dostupni su na zahtjev.

**Ključne riječi:** cijene stambenih nekretnina; precijenjenost; kompozitni indikator; faktorska analiza; makrobonitetna politika.

*Ovaj je rad sažeta verzija cjelovitoga radnog materijala s potpunom metodologijom, validacijskom baterijom, svim tablicama i slikama te detaljnim izvodima; cjelovita verzija, izvorni kôd, obrađeni podaci i Excel replika dostupni su uredništvu na zahtjev. Zbog ograničenja opsega ovdje se prikazuju ključni rezultati i sažet opis postupka.*

# 1. UVODNA RAZMATRANJA

Ciklusi cijena stambenih nekretnina imaju velike makroekonomske i financijske posljedice: kombinacija rasta cijena imovine i kreditne ekspanzije jedan je od najpouzdanijih ranih pokazatelja bankovnih kriza (Borio i Lowe, 2002a), a stambene investicije sustavno prethode recesijama (Leamer, 2007). Hrvatska je prošla oba dijela takva ciklusa: kreditno poduprt rast cijena 2002. – 2008., pri čemu su krediti vezani uz švicarski franak bili važan oblik stambenoga kreditiranja osobito 2005. – 2007. (Hrvatska narodna banka, 2015), te dugu korekciju u kojoj su realne cijene padale i stambene investicije se snažno smanjile. Od 2016. cijene ponovno rastu, a nakon pandemije rast se ubrzao, pa se ponovno nameće pitanje koliko su cijene odmaknule od razina koje podupiru fundamenti.

Za odgovor na to pitanje europske su središnje banke razvile klasu kompozitnih indikatora neusklađenosti (misalignment), koji više parcijalnih pokazatelja, od kojih svaki ima poznata ograničenja, objedinjuju u jednu

mjeru postotnog odstupanja cijena od razine implicirane fundamentima. Metodu su uveli UBS-ov švicarski Bubble Index i Schneiderov rad za Austrijsku narodnu banku (Schneider, 2013), a potom je primijenjena i dograđivana u Sloveniji (Lenarčič i Damjanović, 2015; Damjanović i Lenarčič, 2023), na Malti (Micallef, 2016) i, u metodološki najrazrađenijoj verziji, u Njemačkoj (Hertrich, 2019). Za Hrvatsku kompozitni pokazatelj odstupanja cijena stambenih nekretnina objavljuje Hrvatska narodna banka od 2017., uz kasnije prilagodbe sastava i metodologije (Hrvatska narodna banka, 2017, 2026), a testove eksplozivnosti na hrvatskim cijenama i omjeru cijena i dohotka objavljuje i Dallas Fed u sklopu International House Price Database (Martínez-García i Grossman, 2018).

Ovaj rad toj domaćoj literaturi doprinosi konstrukcijom i usporedbom dviju specifikacija indikatora HPMI-HR: osnovne (sedam pod-indikatora, 2002Q1–2026Q1, 97 kvartala, uzorak koji obuhvaća cijeli ciklus 2002. – 2015.) i proširene (devet pod-indikatora s kreditnim pokazateljima, 2012Q1–2026Q1). Za razliku od jednodimenzionalnih mjera priuštivosti, kompozitni indikator ne odgovara na pitanje što si prosječna plaća može priuštiti, nego jesu li cijene odstupile od fundamenata.

Aktualni je ciklus, uz globalne monetarne uvjete, obilježen domaćim okolnostima koje su pojačale potražnju: uvođenje eura 2023. uklonilo je valutni rizik i snizilo kamatne stope, ulazak u schengenski prostor i turizam povećali su inozemnu potražnju, subvencije stambenih kredita (program APN, 2017. – 2023.) podupirale su domaću potražnju kad su cijene već rasle (Kunovac i Žilić, 2022), a rekordni depoziti uz niske pasivne kamate dio su štednje usmjerili u nekretnine. Zato se, za razliku od ciklusa uoči 2008., rast cijena odvija uz snažan rast plaća i umjeren teret otplate, obrazac koji indikator hvata kroz strukturu doprinosa.

U odnosu na postojeću literaturu rad donosi sljedeće. Pokazatelj agregira relativne jazove prema dugoročnim prosjecima, uz alternativne trendovske reference, i omogućuje iskaz doprinosa u postotnim bodovima; njemački i slovenski pristup sintetizira u jednom okviru i uspoređuje dvije specifikacije na preklopu. Specifikacije uključuju stambene investicije i kamatni rizik prema Taylorovu pravilu, a proširena dodatno nove stambene kredite u odnosu na kreditni kapacitet te vrijednost radova u odnosu na cijene. Doprinos je u kvantifikaciji promjene strukture odstupanja između dvaju ciklusa do prvog tromjesečja 2026. te u sustavnoj provjeri osjetljivosti nalaza na izbor sastavnica, referentnih vrijednosti i ponderiranja, uz BSADF

datiranje eksplozivnih epizoda kao dodatnu dijagnostiku. Dekompozicija doprinosa opisuje strukturu odstupanja u razdobljima obilježenima kreditima vezanima uz švicarski franak, subvencijama stambenih kredita, uvođenjem eura i inozemnom potražnjom, ali ne identificira njihove uzročne učinke. Rad se oslanja isključivo na javne i provjerljive izvore podataka (Državni zavod za statistiku, Hrvatska narodna banka, Eurostat, Europska središnja banka).

## 2. PODACI I METODOLOGIJA

Indikator objedinjuje sedam pod-indikatora u osnovnoj specifikaciji (Tablica 1.): omjer cijena stambenih nekretnina i harmoniziranog indeksa potrošačkih cijena (cijene/HICP, tj. realni indeks cijena), omjer cijena i plaća, omjer cijena i najamnina, omjer cijena i troška gradnje (aproksimacija Tobinova Q za stambene nekretnine, Poterba, 1984; trošak gradnje aproksimiran je indeksom proizvođačkih cijena novih stambenih zgrada), udio stambenih investicija u bruto domaćem proizvodu, omjer cijena i kreditnog kapaciteta (priuštivost) te kamatni rizik (omjer kreditnog kapaciteta pri tržišnoj kamatnoj stopi i pri stopi impliciranoj pravilom monetarne politike). Proširena specifikacija dodaje dva kreditno-ponudbena pokazatelja: omjer novih stambenih kredita i kreditnog kapaciteta (kapacitet otplate) te omjer vrijednosti izvršenih građevinskih radova i cijena. U cijelom se radu za pod-indikatore koriste nazivi iz Tablice 1., pri čemu „cijene" uvijek znači cijene stambenih nekretnina. Ekonomska motivacija svakoga slijedi postojeći korpus (Borio i Lowe, 2002a; Glaeser, Gyourko i Saiz, 2008; Leamer, 2007), a potpun izvod, izvori i postupci spajanja serija dani su u cjelovitoj verziji rada.

Kreditni kapacitet B hipotetski je volumen zaduživanja, iznos kredita koji kućanstvo s danim dohotkom može servisirati uz zadanu stopu i ročnost, za koji se koristi anuitetna formula s plaćanjem unatrag (Hertrich, 2019), uz ročnost od 25 godina i udio otplate u dohotku od 0,4, usklađen s ograničenjem omjera otplate i dohotka koje primjenjuje Hrvatska narodna banka; nije riječ o stvarnom volumenu odobrenih kredita. Referentna kamatna stopa je stopa europodručja, što je opravdano kvazifiksnim tečajem i visokom euroizacijom prije 2023. te izravnom mjerodavnošću Europske središnje banke od uvođenja eura.

Glavno je ograničenje svake hrvatske makrofinancijske analize kratkoća serija s metodološkim lomovima, pa se svaki spoj dokumentira i kvantificira.

Indeks cijena je hedonistički indeks Državnog zavoda za statistiku (PS14, revidirana serija 2002Q1–2026Q1); podudarnost s HNB-ovom serijom J3 na preklopu potvrđena je korelacijom 0,99998 i najvećim odstupanjem od 0,63% nakon rebaziranja, pa spajanje nije potrebno. Kamatna stopa na stambene kredite spaja arhivsku tablicu HNB-a (vagani prosjek, siječanj 2002. do studenoga 2011.) i novu metodologiju kamatne statistike ECB-a (novi poslovi, od prosinca 2011.); razlika na mjestu spoja iznosi −0,06 postotnih bodova. Neto plaća do 2010. kvartalizirana je iz godišnje serije, od 2010. je mjesečna, a prelazak na administrativni izvor JOPPD u siječnju 2016. donosi pomak od −0,1%, unutar uobičajenih sezonskih pomaka. Trošak gradnje je Eurostatov indeks proizvođačkih cijena novih stambenih zgrada (korelacija s DZS-ovom serijom troškova gradnje 1,00 na preklopu od 2010.), najamnine su komponenta HICP-a CP041, a novi stambeni krediti HNB-ova serija od prosinca 2011., u kojoj su kvartali 2015Q4–2016Q2, kada su konverzije kredita u švicarskim francima knjižene kao novi poslovi, zamijenjeni geometrijskom interpolacijom susjednih kvartala. Mjesečne se serije svode na kvartale prosjekom (stope i indeksi) odnosno zbrajanjem (tokovi); plaće, novi krediti i vrijednost radova sezonski su prilagođeni STL dekompozicijom logaritmirane serije (robusna varijanta), dok su BDP i stambene investicije preuzeti sezonski i kalendarski prilagođeni. Potpuna tablica serija, izvora i transformacija dana je u cjelovitoj verziji rada.

Svaki se pod-indikator transformira u jaz, relativno odstupanje od dugoročne referentne vrijednosti. Osnovna je referenca povijesni prosjek uzorka, kao u Lenarčiča i Damjanovića (2015), a kao alternative računaju se jednostrani Hodrick-Prescottov trend s $\lambda = 400.000$, referenca koju koristi Hertrich (2019), i linearni trend za kratke uzorke. Jaz-forma ima uporište u literaturi: ranjivosti se akumuliraju postupno pa razina odstupanja nosi signal (Borio i Lowe, 2002a), a realne cijene stanova imaju deterministički trend povezan s tehnološkim napretkom (Iacoviello i Neri, 2010), pa odstupanje od trenda ima ekonomsku interpretaciju. Svaki je pod-indikator definiran tako da pozitivan jaz upućuje na precijenjenost (omjeri 6, 8 i 9 u Tablici 1. zato su recipročni definicijama iz izvorne literature, vidjeti napomenu uz tablicu); pozitivan jaz pod-indikatora povećava, a negativan smanjuje kompozitni indikator. Ekonomska je logika smjera sljedeća. Rast cijena u odnosu na plaće, najamnine, opću razinu cijena i trošak gradnje znači da cijene rastu brže od kupovne moći, prinosa od najma i zamjenske vrijednosti, pa upućuje na precijenjenost; brži rast plaća, obrnuto, povećava kupovnu moć i istu razinu cijena čini održivijom. Pad omjera cijena i kreditnog kapaciteta znači da

kućanstva uz tekuće kamate i dohotke mogu financirati veći dio cijene, što odstupanje ublažava, dok tržišna kamatna stopa ispod razine iz pravila monetarne politike upućuje na preuzimanje rizika i potiče potražnju. Natprosječan udio stambenih investicija u BDP-u i rast vrijednosti izvršenih radova iznad cijena tumače se kao znak ponudbenog pregrijavanja, tipičan za uzlazne faze ciklusa (Leamer, 2007), premda veća ponuda srednjoročno može djelovati i na smanjenje cijena; ta je ograda razlog za oprez pri tumačenju devetog pokazatelja (napomena uz Tablicu 1.).

Jazovi se agregiraju ponderima iz faktorske analize: svakom se pod-indikatoru pridruži faktor na koji ima najveće opterećenje, a pondere određuje kvadrat opterećenja pomnožen udjelom objašnjene varijance, normiran na jedinicu (Lenarčič i Damjanović, 2015; Hertrich, 2019). Preduvjet, međusobnu koreliranost jazova, potvrđuje Bartlettov test sferičnosti ($\chi^2$ = 514,4; $p \approx 0$), a broj faktora bira se Jolliffeovim i scree kriterijem (Jolliffe, 2002; Stock i Watson, 2002). Kompozit je ponderirani prosjek relativnih jazova odabranih pod-indikatora: pozitivna vrijednost označuje prevagu odstupanja u smjeru precijenjenosti, a tumačenje njegove veličine kao procjene neusklađenosti cijena uvjetovano je izborom referentnih vrijednosti i specifikacije; doprinosi pojedinih pod-indikatora aditivno pokazuju iz kojih komponenti odstupanje dolazi. Uz osnovne pondere iz statične analize glavnih komponenata računaju se i varijante s rotiranom faktorskom analizom te s ponderima na rastućem prozoru (Lansangan i Barrios, 2009). Ukupno se računa 18 varijanti: 12 kombinacija dviju specifikacija, triju referentnih vrijednosti i dviju statičnih metoda ponderiranja, dvije varijante s ponderima na rastućem prozoru uz referencu povijesnog prosjeka te četiri provjere osjetljivosti osnovne specifikacije (ročnost 20 godina, sjenovita kamatna stopa, tri faktora i winsorizacija kamatnog rizika).

Osnovna specifikacija (pod-indikatori 1-7) izvediva je na dugom uzorku od 2002. i time obuhvaća cijeli ciklus 2002. – 2015., ključan za validaciju, dok proširena (svih devet) dodaje pokazatelje novi krediti/kreditni kapacitet i vrijednost radova/cijene, ali tek od 2012. Na preklopu 2012Q1–2026Q1 korelacija dviju specifikacija iznosi 0,976, pa obje specifikacije opisuju isto cikličko kretanje, iako se razlikuju u sastavu i uzorku za procjenu pondera, što je relevantno za zemlje s kratkim kreditnim serijama.

## Tablica 1. Pod-indikatori indikatora HPMI-HR

| # | Pod-indikator | Definicija | Perspektiva | Spec. |
|---|---|---|---|---|
| 1 | Cijene stambenih nekretnina / HICP (realni indeks cijena) | $P_h$ / HICP | potražnja | osnovna |
| 2 | Cijene stambenih nekretnina / plaće | $P_h$ / W | potražnja | osnovna |
| 3 | Cijene stambenih nekretnina / najamnine | $P_h$ / najamnine | ponuda/investitor | osnovna |
| 4 | Cijene stambenih nekretnina / trošak gradnje (Tobinov Q) | $P_h$ / trošak gradnje | ponuda | osnovna |
| 5 | Stambene investicije / BDP | I(stan) / BDP | makro/ciklus | osnovna |
| 6 | Cijene stambenih nekretnina / kreditni kapacitet (priuštivost) | $P_h$ / B | potražnja | osnovna |
| 7 | Kamatni rizik | $B(i_{EURIBOR})$ / $B(i_{Taylor})$ | monetarna | osnovna |
| 8 | Novi stambeni krediti / kreditni kapacitet (kapacitet otplate) | novi stambeni krediti / B | bankovna | proširena |
| 9 | Vrijednost radova / cijene stambenih nekretnina | vrijednost radova / $P_h$ | ponuda | proširena |

Izvor: izrada autora prema Hertrich (2019), Lenarčič i Damjanović (2015) i Damjanović i Lenarčič (2023); potpune definicije u cjelovitoj verziji rada. Oznake: $P_h$ = indeks cijena stambenih nekretnina; HICP = harmonizirani indeks potrošačkih cijena; W = prosječna plaća; B = kreditni kapacitet, hipotetski volumen zaduživanja iz anuitetne formule (ne stvarni volumen kredita); i = kamatna stopa. Trošak gradnje aproksimiran je indeksom proizvođačkih cijena novih stambenih zgrada (Eurostat). Svaki je pod-indikator definiran tako da rast znači signal precijenjenosti: pokazatelji 6 i 8 recipročni su Hertrichovim (2019) omjerima priuštivosti ($B/P_h$) i kapaciteta otplate (B/novi krediti), kako i ulaze u njegov kompozit; pokazatelj 9 recipročan je definiciji u Damjanović i Lenarčič (2023), jer se rast vrijednosti izvršenih radova iznad cijena ovdje tumači kao znak ponudbenog pregrijavanja, analogno udjelu stambenih investicija u BDP-u.

Dobiveni ponderi (Tablica 2.) potvrđuju dominaciju cjenovnih omjera: u osnovnoj specifikaciji tri omjera (cijene/plaće, cijene/HICP i cijene/najamnine) nose zajedno oko 62% težine, dok kamatni rizik nosi najmanju (4,5%), slično kao u Hertrichovoj primjeni za Njemačku. U proširenoj se specifikaciji težina preraspodjeljuje prema kreditno-ponudbenim pokazateljima.

**Tablica 2. Ponderi pod-indikatora (u%)**

| Pod-indikator | Osnovna (%) | Proširena (%) |
|---|---|---|
| Cijene/plaće | 21,0 | 12,5 |
| Cijene/HICP | 20,3 | 15,6 |
| Cijene/najamnine | 20,3 | 14,7 |
| Stambene investicije/BDP | 12,8 | 13,7 |
| Cijene/kreditni kapacitet | 11,6 | 3,0 |
| Cijene/trošak gradnje | 9,5 | 11,2 |
| Kamatni rizik | 4,5 | 2,8 |
| Vrijednost radova/cijene | — | 12,4 |
| Novi krediti/kreditni kapacitet | — | 14,1 |

Izvor: izračun autora (osnovna varijanta prosjek/PCA). Znak — označava pokazatelje kojih nema u osnovnoj specifikaciji.

# 3. REZULTATI I DEKOMPOZICIJA

Osnovna specifikacija pokazuje pozitivan jaz od 14,7% u prvom tromjesečju 2026., što upućuje na cijene stambenih nekretnina u Hrvatskoj oko 15% iznad razine koju podupiru fundamenti. Slika 1. prikazuje indikator s dekompozicijom doprinosa za razdoblje 2002Q1–2026Q1: indikator opisuje otprilike jedan i pol stambeni ciklus s tri jasno odvojene epizode (Tablica 3.). Kroz 18 varijanti vrijednost za 2026Q1 kreće se u rasponu +10,0% do +26,6%: predznak je stabilan, dok veličina znatno ovisi o specifikaciji, a gornju granicu određuje proširena specifikacija u kojoj kreditna ekspanzija iz 2025. ulazi punom težinom (+25,3%).

Retrospektivno, indikator ispravno datira prošli ciklus. Na vrhuncu uzlazne faze (2007Q3, +20,2%) najveći doprinos daju cijene/plaće i cijene/kreditni kapacitet (pogoršana priuštivost), obilježja kreditno pogonjenog rasta, dijelom kroz kredite vezane uz švicarski franak (Hrvatska narodna banka, 2015). Dno korekcije indikator smješta u 2015Q2 (−16,8%), uz sve komponente negativne i izrazito nisku građevinsku aktivnost; razdoblje 2013.–2016. bilo je, retrospektivno, interval najveće podcijenjenosti, a subvencije stambenih kredita uvedene su 2017., kad se negativni jaz već zatvarao (Kunovac i Žilić, 2022).

Ključni je nalaz da današnje odstupanje nema istu strukturu kao 2007.: doprinos cijene/plaće pao je s +5,9 boda u 2007Q3 na +1,4 u 2026Q1, cijene/kreditni kapacitet s +3,1 na −1,2, dok je doprinos cijene/HICP porastao

s +4,5 na +9,1 boda. U 2026Q1 oko dvije trećine odstupanja nosi realni cjenovni jaz, odstupanje omjera cijene/HICP od referentne vrijednosti (+9,1 postotna boda), petinu investicije/BDP (+3,0 boda), dok cijene/plaće i cijene/najamnine pridonose umjereno (po +1,4 boda), jer su nominalne plaće 2022. – 2025. dijelom sustigle cijene, a službeni indeks najamnina snažno je porastao u 2025.; Hrvatska narodna banka (2026) skok tog indeksa u trećem tromjesečju 2025. pripisuje povećanju socijalnih najamnina, pa smanjenje jaza cijene/najamnine ne treba u cijelosti poistovjećivati s poboljšanjem odnosa cijena i tržišnih najamnina. Cijene/kreditni kapacitet (−1,2 boda) i kamatni rizik (−0,7 boda) odstupanje smanjuju. Odstupanje je, ukratko, cjenovno-investicijsko, a ne kreditno-priuštivosno.

Budući da realni cjenovni jaz dominira, treba spriječiti njegovo čitanje kao tautologije („cijene su precijenjene jer su visoke”): pod-indikator mjeri odstupanje realne cijene od dugoročne reference, a ne razinu cijena, a da odstupanje nije tek posljedica konvergencije pokazuje robusnost na izbor reference (linearni trend +14,1%, jednostrani Hodrick-Prescottov trend +10,1% u 2026Q1, naspram +14,7%).

**Slika 1. HPMI-HR (osnovna specifikacija) s dekompozicijom doprinosa, 2002Q1–2026Q1**

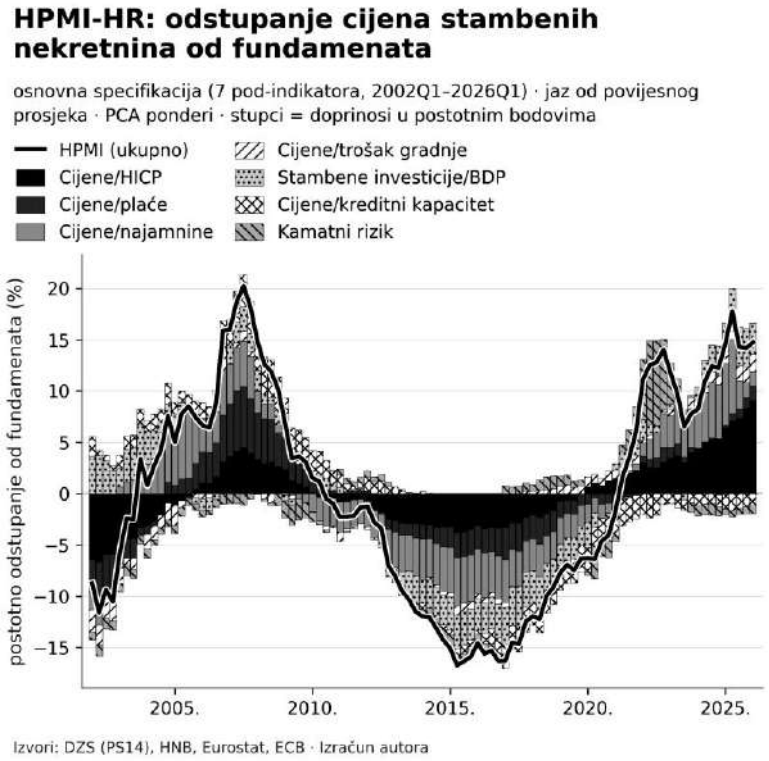


Izvor: izračun autora. Stupci su doprinosi pod-indikatora u postotnim bodovima; crna linija je HPMI. Podaci: DZS, HNB, Eurostat, ECB.

**Tablica 3. Epizode i dekompozicija**

| Epizoda | HPMI | Glavni doprinosi (postotni bodovi) |
|---|---|---|
| Vrhunac uzlazne faze 2007Q3 | +20,2% | cijene/plaće +5,9; cijene/HICP +4,5; cijene/najamnine +4,5; cijene/kreditni kapacitet +3,1 |
| Dno korekcije 2015Q2 | −16,8% | sve komponente negativne: cijene/najamnine −4,7; cijene/HICP −3,8; investicije/BDP −3,3 |
| Vrhunac nakon pandemije 2025Q2 | +17,8% | cijene/najamnine +7,3; cijene/HICP +7,1; investicije/BDP +3,3; cijene/trošak gradnje +1,7; cijene/plaće +0,7; cijene/kreditni kapacitet −1,6; kamatni rizik −0,6 |
| Zadnje opažanje 2026Q1 | +14,7% | cijene/HICP +9,1; investicije/BDP +3,0; cijene/trošak gradnje +1,7; cijene/najamnine +1,4; cijene/plaće +1,4; cijene/kreditni kapacitet −1,2; kamatni rizik −0,7 |

Izvor: izračun autora (osnovna specifikacija, osnovna varijanta prosjek/PCA). Potpuna dekompozicija po kvartalima dana je u cjelovitoj verziji rada. Zbroj zaokruženih doprinosa može se od vrijednosti indikatora razlikovati za 0,1 postotni bod.

Slika 2. prikazuje pod-indikatore pojedinačno, u jaz-formi. Već na toj razini vidljiva je razlika između dvaju ciklusa: u aktualnom je najveći realni cjenovni jaz (cijene/HICP na kraju uzorka oko 45% iznad povijesnog prosjeka, najviše u uzorku), dok je cijene/kreditni kapacitet ispod prosjeka, tj. priuštivost je bolja od prosječne, obrnuto nego 2007., kada su svi potražni jazovi rasli istodobno.

**Slika 2. Pod-indikatori u jaz-formi (postotno odstupanje od dugoročnog prosjeka)**

Izvor: izračun autora. Nazivi pod-indikatora kao u Tablici 1; svi su orijentirani tako da rast znači signal precijenjenosti.

## 4. VALIDACIJA I ROBUSNOST

Vjerodostojnost indikatora provjerava se u više slojeva; potpun protokol dan je u cjelovitoj verziji rada. Prvo, ciklička komponenta realnog indeksa cijena iz triju frekvencijskih filtara (dvostrani Hodrick-Prescottov, Baxter-Kingov i Hamiltonov; Baxter i King, 1999; Hamilton, 2018) sinkronizirana je s indikatorom prema testu sinkronizacije faza (Mink, Jacobs i de Haan, 2012; Meller i Metiu, 2017). Drugo, tri različita pravila za identifikaciju epizoda (Goodhart i Hofmann, 2008; Kindleberger i Aliber, 2005; André, 2010) identificiraju iste dvije epizode pregrijavanja: 2004. – 2009. i onu od 2020./2021.

Treće, kao dodatna dijagnostika primijenjeno je BSADF datiranje eksplozivnih epizoda (Phillips, Shi i Yu, 2015a, 2015b) na realni indeks cijena (duga serija BIS-a od 1997., deflacionirana HICP-om) i na omjer cijene/plaće, ne na sam kompozit; test datira eksplozivne epizode 2006Q4–2008Q1 i od 2020Q4 (u tijeku). Usporedive pokazatelje eksplozivnosti za Hrvatsku objavljuje i Dallas Fed (Martínez-García i Grossman, 2018). Četvrto, kao dodatna provjera reproduciran je skup modela Europske središnje banke (ECB, 2011): tri od četiri pokazatelja upućuju na precijenjenost sličnog reda veličine, dok četvrti, koji uzima u obzir trošak financiranja, trenutno pokazuje suprotno, zbog neuobičajeno niskih kamata.

Datiranje eksplozivnih epizoda pokazuje da vrhunci kompozita ne odražavaju tek postupan rast, nego razdoblja eksplozivnog ponašanja ispitanih serija; obje detektirane epizode, 2006Q4–2008Q1 i ona koja traje od 2020Q4, vremenski se poklapaju s vrhuncima kompozita. Amplituda uzlazne faze (+20,2% u 2007.) usporediva je sa slovenskom (Lenarčič i Damjanović, 2015; Damjanović i Lenarčič, 2023), a znatno veća od njemačke (Hertrich, 2019), što je u skladu s razmjerima hrvatskoga ciklusa, uz oprez zbog razlika u sastavu, referentnim vrijednostima i uzorcima tih indikatora.

Slika 3. sažima raspon rezultata odabranih varijanti: kroz 18 varijanti opisanih u drugom poglavlju vrijednost za 2026Q1 kreće se od +10,0% do +26,6%, bez promjene predznaka; pojedine varijante daju jednak rezultat, pa raspon nije interval pouzdanosti. Rezultat ne ovisi ni o izboru između raspoloživih inačica ulaznih serija (indeks cijena DZS-a naspram HNB-a, spoj kamatne serije, sjenovita kamatna stopa; Damjanović i Masten, 2016; Wu i Xia, 2016).

**Slika 3. Robusnost: sve metodološke varijante pokazuju isti ciklus**

Izvor: izračun autora. Osjenčano je min–max raspon 11 varijanti osnovne specifikacije; puna linija je osnovna, isprekidana proširena specifikacija (osnovna varijanta).

# 5. RASPRAVA: UVJETI FINANCIRANJA, ŠTEDNJA I IMPLIKACIJE ZA POLITIKU

Dekompozicija pokazuje da cijene/kreditni kapacitet (priuštivost) i kamatni rizik danas smanjuju odstupanje. Taj nalaz treba čitati s oprezom jer dijelom proizlazi iz uvjeta financiranja koji su iznimno povoljni: hrvatske su kamatne stope na stambene kredite među najnižima u europodručju (2,95% naspram prosjeka od 3,43% u travnju 2026.). Dio je objašnjenja slab kamatni prijenos: u razdoblju postpandemijskog zatezanja od travnja 2022. prosječan prijenos referentnih stopa Europske središnje banke na bankovne kamatne stope u Hrvatskoj bio je četvrti najslabiji u europodručju, a autori upozoravaju da slaba transmisija može pridonijeti napuhavanju cijena imovine, osobito nekretnina (Tica i Balatinec, 2025). Niske su stope povezane i s dvjema

domaćim pojavama: depoziti kućanstava nominalno su na rekordnih 42,3 milijarde eura, ali realno tek na razini iz 2021., uz pasivne kamate blizu nule, a stambeni i gotovinski krediti rastu oko 15% godišnje, višestruko brže nego u europodručju.

Povoljna priuštivost, koja danas ublažava izmjerenu precijenjenost, dijelom stoga počiva na neuobičajeno niskim kamatama i obilnoj likvidnosti; normalizacija pasivnih kamata ili zaokret u ponašanju štediša djelovali bi u suprotnom smjeru. Jeftin kredit sliku precijenjenosti ublažava, ali je ne pobija, što pokazuje i skup modela Europske središnje banke.

Ta pojava ima i strukturnu dimenziju: uz gotovo nulte pasivne kamate realna vrijednost depozita godinama stagnira, pa dio kućanstava štednju usmjerava u nekretnine kao oblik očuvanja vrijednosti, neovisno o kreditnim uvjetima. Istodobno kreditni impuls od oko 15% godišnje u proširenoj specifikaciji postaje vidljiv od 2025. i podiže je iznad osnovne. Za makrobonitetnu politiku to znači da se kreditni kanal, iako odstupanje primarno nose cijene i investicije, ponovno aktivira i da bi njegovo jačanje moglo pomaknuti strukturu rizika prema onoj iz prethodnog ciklusa.

Iz rezultata slijede implikacije za makrobonitetnu politiku. Budući da odstupanje danas nose cijene i investicije, a kreditna komponenta tek ponovno jača (proširena specifikacija), instrumenti poput ograničenja omjera otplate i dohotka (DSTI) te omjera kredita i vrijednosti nekretnine (LTV) dobivaju na važnosti kao sredstva kojima se rast cijena ne prenosi u rast sistemskog rizika kroz zaduživanje. Indikator je pritom prikladan i za mjesečno praćenje signala između kvartalnih objava jer se glavnina pod-indikatora ažurira mjesečno.

Rezultate treba tumačiti uz nekoliko ograničenja. Fundamentalna vrijednost nije izravno opažljiva, pa je svaka procjena precijenjenosti relativna; uzorak od 2002. pokriva oko jedan i pol ciklus, pa jaz od prosjeka ovisi o uzorku; ne postoji domaća epizoda sloma za strogu evaluaciju svojstava ranog upozorenja. Pokazatelj cijene/HICP koristi opću razinu potrošačkih cijena, a ne plaću, kao nazivnik, pa ne razlikuje pravu precijenjenost od rasta cijena i plaća iznad opće inflacije tijekom dohodovne konvergencije (Balassa-Samuelsonov efekt). Analiza je retrospektivna: referentne vrijednosti i ponderi procjenjuju se na cijelom raspoloživom uzorku, pa rezultati ne pokazuju svojstva procjene u stvarnom vremenu. Službeni indeks najamnina (HICP, komponenta CP041) uključuje i regulirane najamnine, pa je njegova

reprezentativnost za tržišne prinose ograničena. Potpuna rasprava o ograničenjima dana je u cjelovitoj verziji rada.

## 6. ZAKLJUČNA RAZMATRANJA

HPMI-HR pokazuje pozitivan jaz u prvom tromjesečju 2026. u svim ispitanim varijantama, uz znatnu osjetljivost njegove veličine na metodološke izbore: osnovna specifikacija iznosi +14,7%, a raspon odabranih varijanti +10,0% do +26,6%. Indikator retrospektivno ispravno datira prošli ciklus, a dekompozicija osnovne specifikacije pokazuje promjenu strukture odstupanja u odnosu na 2007.: veći doprinos omjera cijene/HICP i stambenih investicija te manji doprinos omjera cijene/plaće i povoljniji doprinos kreditne priuštivosti. Nalazi dopunjuju postojeće domaće analize (Hrvatska narodna banka, 2017, 2026), uz ograničenja odabranih referentnih vrijednosti i ulaznih pokazatelja.

Indikator ne predviđa trenutak ni oblik prilagodbe: precijenjenost se povijesno smanjivala i stagnacijom nominalnih cijena uz rast fundamenata i korekcijom poput one nakon 2008. Slijede formalizacija okvira za mjesečno praćenje i redovita objava indikatora na javnom portalu; potpuna metodologija i validacija dane su u cjelovitoj verziji rada.

*Napomena o korištenim alatima*

Za dohvat podataka i izradu skripti za statističku obradu (transformacije serija, faktorska analiza, frekvencijski filtri i BSADF test) autor je koristio alat Claude Code (Anthropic). Autor je provjerio sve rezultate i preuzima punu odgovornost za sadržaj rada.

# LITERATURA

André, C. (2010). A Bird's Eye View of OECD Housing Markets. OECD Economics Department Working Paper No. 746. OECD Publishing. https://doi.org/10.1787/5kmlh5qvz1s4-en

Baxter, M. i King, R. G. (1999). Measuring business cycles: approximate band-pass filters for economic time series. Review of Economics and Statistics, 81(4), 575–593. https://doi.org/10.1162/003465399558454

Borio, C. i Lowe, P. (2002a). Asset prices, financial and monetary stability: exploring the nexus. BIS Working Paper No. 114. Bank for International Settlements. https://www.bis.org/publ/work114.htm

Damjanović, M. i Lenarčič, Č. (2023). Constructing a house price misalignment indicator: revisited and revamped. MPRA Paper No. 118489. University Library of Munich. https://mpra.ub.uni-muenchen.de/118489/

Damjanović, M. i Masten, I. (2016). Shadow short rate and monetary policy in the euro area. Empirica, 43(2), 279–298. https://doi.org/10.1007/s10663-016-9328-4

ECB (2011). Tools for detecting a possible misalignment of residential property prices from fundamentals. Financial Stability Review, lipanj 2011., Box 3, 57–59. Europska središnja banka. https://www.ecb.europa.eu/pub/pdf/fsr/financialstabilityreview201106en.pdf

Glaeser, E. L., Gyourko, J. i Saiz, A. (2008). Housing supply and housing bubbles. Journal of Urban Economics, 64(2), 198–217. https://doi.org/10.1016/j.jue.2008.07.007

Goodhart, C. i Hofmann, B. (2008). House prices, money, credit, and the macroeconomy. Oxford Review of Economic Policy, 24(1), 180–205. https://doi.org/10.1093/oxrep/grn009

Hamilton, J. D. (2018). Why you should never use the Hodrick-Prescott filter. Review of Economics and Statistics, 100(5), 831–843. https://doi.org/10.1162/rest_a_00706

Hertrich, M. (2019). A novel housing price misalignment indicator for Germany. German Economic Review, 20(4), 759–794. https://doi.org/10.1111/geer.12185

Hrvatska narodna banka (2015). Izvješće o problematici zaduženosti građana kreditima u švicarskim francima i prijedlozima mjera za olakšavanje položaja dužnika u švicarskim francima na temelju zaključka Odbora za financije i državni proračun Hrvatskog sabora (rujan 2015.). HNB. https://www.hnb.hr/documents/20182/447389/hp15092015_CHF.pdf/6e84815b-eb41-4315-96a2-9ecf5b8c6183

Hrvatska narodna banka (2017). Okvir 2: Odstupanje cijena stambenih nekretnina od intrinzične vrijednosti u Hrvatskoj. Financijska stabilnost, 18 (svibanj 2017.), 27–29. HNB. https://www.hnb.hr/documents/20182/1972383/ h-fs-18-2017.pdf

Hrvatska narodna banka (2026). Financijska stabilnost, 27 (lipanj 2026.). HNB. https://www.hnb.hr/documents/d/guest/h-fs-27

Iacoviello, M. i Neri, S. (2010). Housing market spillovers: evidence from an estimated DSGE model. American Economic Journal: Macroeconomics, 2(2), 125–164. https://doi.org/10.1257/mac.2.2.125

Jolliffe, I. T. (2002). Principal Component Analysis (2. izd.). Springer. https://doi.org/10.1007/b98835

Kindleberger, C. P. i Aliber, R. Z. (2005). Manias, Panics and Crashes: A History of Financial Crises (5. izd.). Palgrave Macmillan. https://doi.org/10.1057/9780230628045

Kunovac, D. i Žilić, I. (2022). The effect of housing loan subsidies on affordability: evidence from Croatia. Journal of Housing Economics, 55, 101808. https://doi.org/10.1016/j.jhe.2021.101808

Lansangan, J. R. G. i Barrios, E. B. (2009). Principal components analysis of nonstationary time series data. Statistics and Computing, 19(2), 173–187. https://doi.org/10.1007/s11222-008-9082-y

Leamer, E. E. (2007). Housing IS the business cycle. NBER Working Paper No. 13428. National Bureau of Economic Research. https://doi.org/10.3386/w13428

Lenarčič, Č. i Damjanović, M. (2015). Slovene Residential Property Prices Misalignment with Fundamentals. Surveys and Analyses 2/2015. Banka Slovenije.

Martínez-García, E. i Grossman, V. (2018). Explosive dynamics in house prices? An exploration of financial market spillovers in housing markets

around the world. Globalization Institute Working Paper No. 342 (revidirano). Federal Reserve Bank of Dallas. https://doi.org/10.24149 /gwp342r1

Meller, B. i Metiu, N. (2017). The synchronization of credit cycles. Journal of Banking & Finance, 82, 98–111. https://doi.org/10.1016/j.jbankfin. 2017.05.011

Micallef, B. (2016). Property Price Misalignment with Fundamentals in Malta. Working Paper WP/03/2016. Central Bank of Malta.

Mink, M., Jacobs, J. P. A. M. i de Haan, J. (2012). Measuring coherence of output gaps with an application to the euro area. Oxford Economic Papers, 64(2), 217–236. https://doi.org/10.1093/oep/gpr049

Phillips, P. C. B., Shi, S. i Yu, J. (2015a). Testing for multiple bubbles: historical episodes of exuberance and collapse in the S&P 500. International Economic Review, 56(4), 1043–1078. https://doi.org/10.1111/iere.12132

Phillips, P. C. B., Shi, S. i Yu, J. (2015b). Testing for multiple bubbles: limit theory of real-time detectors. International Economic Review, 56(4), 1079–1134. https://doi.org/10.1111/iere.12131

Poterba, J. M. (1984). Tax subsidies to owner-occupied housing: an asset-market approach. The Quarterly Journal of Economics, 99(4), 729–752. https://doi.org/10.2307/1883123

Schneider, M. (2013). Are recent increases of residential property prices in Vienna and Austria justified by fundamentals? Monetary Policy & the Economy, Q4/13, 29–46. Oesterreichische Nationalbank.

Stock, J. H. i Watson, M. W. (2002). Forecasting using principal components from a large number of predictors. Journal of the American Statistical Association, 97(460), 1167–1179. https://doi.org/10.1198/016214502388618960

Tica, J. i Balatinec, M. (2025). Kamatni prijenos u eurozoni u razdoblju postpandemijske restriktivne monetarne politike. EFZG Working Paper Series, 2025(2), 1–19. Sveučilište u Zagrebu, Ekonomski fakultet. https://hrcak.
srce.hr/327840

Wu, J. C. i Xia, F. D. (2016). Measuring the macroeconomic impact of monetary policy at the zero lower bound. Journal of Money, Credit and Banking, 48(2–3), 253–291. https://doi.org/10.1111/jmcb.12300

# A HOUSING PRICE MISALIGNMENT INDICATOR FOR CROATIA (HPMI-HR): CONSTRUCTION, DECOMPOSITION AND VALIDATION

***Abstract***

*This paper constructs a composite housing price misalignment indicator (HPMI) for Croatia in two specifications and estimates the size and structure of the deviation of house prices from fundamentals in early 2026. Seven sub-indicators from the demand, supply and systemic perspectives (baseline specification, 2002Q1–2026Q1) and nine sub-indicators (extended specification, 2012Q1–2026Q1) are transformed into gaps from a long-run reference and aggregated using factor-analytic weights, following the methodology applied by the Bundesbank, the Bank of Slovenia, the Central Bank of Malta and the Croatian National Bank. The baseline specification shows a positive gap of 14.7% in 2026Q1, indicating prices about 15% above the level supported by fundamentals; the range across 18 variants is +10.0% to +26.6%. The decomposition shows that today's deviation is driven by the real price gap and high residential investment rather than by the income and credit components that dominated in 2007. The result is relevant for calibrating macroprudential limits (DSTI/LTV). Fundamental value is unobservable; the sample covers about one and a half cycles; there is no domestic bust episode for a strict early-warning evaluation; the price/HICP sub-indicator cannot separate overvaluation from income convergence. The paper contributes to the existing analyses of Croatia's housing market, including the Croatian National Bank's composite indicator, by comparing baseline and extended composite indicator specifications, quantifying changes in the composition of misalignment across two housing cycles, and examining sensitivity to methodological choices using data through 2026Q1. The procedure relies exclusively on public sources; code and data are available on request.*

***Keywords:*** *residential property prices; overvaluation; composite indicator; factor analysis; macroprudential policy.*

JEL klasifikacija: H55, G22, G28

Izvorni znanstveni rad

# STRUKTURNA ODRŽIVOST POSLOVNOG MODELA MIROVINSKIH OSIGURAVAJUĆIH DRUŠTAVA U REPUBLICI HRVATSKOJ[1]

Darko Horvatin*

Dražen Derado**

## SAŽETAK

Mirovinska osiguravajuća društva (MOD) predstavljaju važan institucionalni element reformiranoga mirovinskog sustava u Republici Hrvatskoj jer omogućuju pretvaranje akumulirane štednje iz obveznih mirovinskih fondova u doživotne mirovinske primitke. Unatoč njihovoj važnosti i snažnom rastu sektora, financijska održivost poslovnog modela MOD-ova ostaje nedovoljno istražena u domaćoj literaturi. Rad analizira održivost poslovnog modela MOD-ova na temelju agregatnih podataka sektora za razdoblje 2020. – 2025., te projekcija kapitalnih potreba u razdoblju 2026. – 2030., s ciljem utvrđivanja u kojoj mjeri postojeći regulatorni okvir omogućuje društvima da iz interno generirane dobiti financiraju rast kapitalnih zahtjeva povezanih s

* Doc. dr. sc. Darko Horvatin, Zagrebačka škola ekonomije i managementa (e-mail: darko.horvatin@zsem.hr), korespondirajući autor.

** Prof. dr. sc. Dražen Derado, Sveučilište u Splitu, Ekonomski fakultet (e-mail: dderado@efst.hr).

[1] Ovaj rad je rezultat istraživanja provedenog u okviru projekta Suvremeni izazovi održivosti u kontekstu globalnih promjena (CHASING), koji je financiran iz izvora 581 – Mehanizam za oporavak i otpornost.

povećanjem tehničkih pričuva i preuzetim mirovinskim obvezama. Analiza se temelji na financijskim izvještajima dvaju hrvatskih MOD-ova te na Damodaranovu pristupu vrednovanju reguliranih financijskih institucija, prilagođenom za specifičnosti sektora. Kao pokazatelj kapitalne samoodrživosti koristi se slobodni novčani tijek vlasnicima (SNTV), pri čemu se rast regulatorno potrebnog kapitala promatra kao funkcionalni ekvivalent kapitalnih ulaganja nužnih za nastavak poslovanja. U povijesnoj analizi SNTV se izračunava na temelju stvarnog prirasta potrebne granice solventnosti (PGS), dok se u projekcijskom modelu koristi pokazatelj potrebnog prirasta kapitala (PPK), definiran kao kapital potreban za održavanje kapitalne pozicije na razini 120% PGS-a, odnosno približno 4,8% prirasta tehničkih pričuva (TP). Rad testira dvije istraživačke hipoteze. Prema prvoj hipotezi (H1), temeljenoj na povijesnim podacima za razdoblje 2020. – 2025., rast tehničkih pričuva MOD-ova sustavno generira kapitalne zahtjeve koje sektor ne uspijeva pokriti interno generiranom dobiti. Prema drugoj hipotezi (H2), i projekcijama kapitalnih potreba sektora za razdoblje 2026. – 2030., čak ni očekivani ubrzani priljev korisnika iz drugog mirovinskog stupa u sektor mirovinskih osiguravajućih društava neće otkloniti potrebu za kontinuiranim kapitalnim injekcijama vlasnika. Empirijski rezultati za razdoblje 2020. – 2025. pokazuju ograničenu sposobnost sektora za organsko financiranje rasta kapitalnih potreba, dok projekcije do 2030. godine upućuju na potreban daljnji rast tehničkih pričuva u svim analiziranim scenarijima. Rezultati pružaju potporu tezi o ograničenoj organskoj samoodrživosti postojećega poslovnog modela hrvatskih MOD-ova, te opravdavaju razmatranje regulatornih prilagodbi, uključujući mogućnost šireg priznavanja raspoloživih kapitalnih rezervi i dugoročni prijelaz prema kapitalnim zahtjevima utemeljenima na stvarnom rizičnom profilu portfelja.

**Ključne riječi:** mirovinska osiguravajuća društva, solventnost, kapitalna adekvatnost, tehničke pričuve, slobodni novčani tijek vlasnicima.

# 1. UVOD

Reformom mirovinskog sustava iz 2002. godine Republika Hrvatska uvela je trostupanjski mirovinski model u kojemu drugi stup – obvezna kapitalizirana osobna štednja – zauzima ključno mjesto kao mehanizam smanjenja dugoročnih fiskalnih pritisaka na državni proračun. Kapital koji osiguranici akumuliraju u obveznim mirovinskim fondovima (OMF) kroz radni vijek prenosi se po odlasku u mirovinu u mirovinska osiguravajuća društva (MOD)

koja ga potom transferiraju u doživotnu mirovinsku rentu. MOD-ovi time preuzimaju specifičnu kombinaciju rizika među kojima: biometrički rizik (dugovječnost korisnika), financijski rizik (prinos na imovinu za pokriće tehničkih pričuva) i regulatorni rizik (promjene kapitalnih zahtjeva). Za razliku od klasičnih životnih osiguravatelja koji nude širok spektar proizvoda, MOD-ovi imaju izrazito uzak poslovni model prema kojemu jedini prihod čini naknada za upravljanje (jednokratna naknada i godišnja naknada razmjerna iznosu doznake), dok je struktura obveza jednoznačno definirana tehničkim pričuvama.

Unatoč strateškom značaju ove institucije za mirovinski sustav Republike Hrvatske, financijska održivost MOD-ova u domaćoj akademskoj i regulatornoj literaturi još uvijek nije bila predmetom sustavne empirijske analize. Stoga, ovaj rad nastoji popuniti tu prazninu. Pritom, cilj rada je, uvažavajući važnost MOD-ova u novoj „arhitekturi" mirovinskog sustava Republike Hrvatske, analizirati samoodrživost njihova poslovnog modela, te utvrditi postojanje prostora za njegovo eventualno unaprjeđenje.

Svrha rada je doprinijeti široj raspravi o dugoročnoj održivosti mirovinskog sustava s naglaskom na financijski i socijalno najosjetljiviji dio mirovinske reforme – isplatu mirovina. Naime, očekivanja stručne javnosti i svih dionika ovog reformskog procesa bila su da će u sadašnjoj fazi reforme mirovinskog sustava, s većim priljevom sredstava iz drugog mirovinskog stupa prema mirovinskim osiguravajućim društvima, na tržištu biti prisutno više MOD-ova. Budući da se to nije dogodilo, nameće se pitanje razloga i prikladnosti njihova aktualnog poslovnog modela i pripadajuće regulative. Visoki kapitalni zahtjevi, koji rastu s povećanjem imovine, vjerojatno predstavljaju previsoku barijeru za ulazak novih društava na tržište. Naime, sadašnji poslovni model karakterom više podsjeća na javnu uslugu nego na tržištu djelatnost što predstavlja suštinski razlog upitne profitabilnosti MOD-ova, dok se negativni slobodni novčani tijek za vlasnike ne javlja kao iznimka, već kao inherentno obilježje modela. Sukladno tome, u radu se testiraju sljedeće hipoteze:

H1: Sadašnji poslovni model MOD-ova pokazuje obilježja ograničene organske samoodrživosti.

H2: Očekivano ubrzanje priljeva novca iz drugog mirovinskog stupa u razdoblju 2026. – 2030. neće riješiti problem samoodrživosti MOD-ova, već će povećati apsolutnu razinu potreba za dodatnim kapitalom.

Rad je organiziran u sedam poglavlja. Nakon uvoda, u drugom poglavlju slijede teorijska razmatranja pojma kapitalne samoodrživosti s naglaskom na metodologiju slobodnog novčanog tijeka vlasnicima (SNTV[2]) i pregled relevantne empirijske literature. Treće poglavlje opisuje regulatorni kontekst u kojemu posluju MOD-ovi u Hrvatskoj. Četvrto poglavlje prikazuje agregatnu empirijsku analizu hrvatskih mirovinskih osiguravajućih društava, dok se u petom poglavlju projiciraju njihove kapitalne potrebe do 2030. godine. Na temelju rezultata provedene analize šesto poglavlje nudi prijedlog regulatornih unapređenja, dok sedmo poglavlje daje zaključak.

## 2. TEORIJSKI OKVIR I PREGLED RELEVANTNE EMPIRIJSKE LITERATURE

U korporativnim financijama slobodni novčani tijek za vlasnike mjeri novčani iznos koji ostaje vlasnicima nakon podmirenja svih obveza. Standardni izraz slobodnog novčanog tijeka za nefinancijsko poduzeće (Damodaran, 2012) glasi:

$$SNTV = \textit{neto-dobit} + \textit{amortizacija} - \textit{kapitalni izdaci} - \Delta\textit{radni kapital} - \textit{otplata duga} + \textit{novo zaduživanje} \quad (1)$$

Prema izrazu (1) slobodni novčani tijek (SNTV) predstavlja rezultat zbroja neto-dobiti, amortizacije i novog zaduživanja umanjenog za kapitalne izdatke, promjenu radnog kapitala i iznos otplate duga[3]. Pozitivni SNTV znači da poduzeće generira višak novca kojega je moguće isplatiti vlasnicima bez ugrožavanja poslovanja, dok negativni SNTV znači da poduzeće troši više kapitala nego što ga organski stvara, te mora pribjeći vanjskom financiranju. Pritom, SNTV nije istoznačan pojmu računovodstvene dobiti,

[2] Koncept i metodologiju mjerenja slobodnog novčanog tijeka vlasnicima (engl. *Free Cash Flow to Equity – FCFE*) razvio je Aswath Damodaran, profesor financija na poslovnoj školi *Stern School of Business* Sveučilišta u New Yorku, jedan od vodećih svjetskih autoriteta u području procjene vrijednosti poduzeća, s brojnim radovima iz korporativnih financija i upravljanja imovinom.

[3] Kapitalni izdaci (engl. *capital expenditures – CAPEX*) predstavljaju ulaganja u dugotrajnu imovinu potrebnu za poslovanje. Radni kapital predstavlja razliku između kratkotrajne poslovne imovine i kratkoročnih poslovnih obveza. Njegovo povećanje ($\Delta$*radni kapital* > 0), primjerice zbog rasta potraživanja ili zaliha, veže novčana sredstva i smanjuje SNTV, dok njegovo smanjenje ($\Delta$*radni kapital* < 0) oslobađa novčana sredstva i povećava SNTV. Budući da pokazatelj promjene radnog kapitala u izrazu (1) ima negativni predznak, njegov rast smanjuje, a pad povećava SNTV. Novo zaduživanje povećava raspoloživi novčani tijek vlasnicima, dok otplata glavnice duga taj tijek smanjuje. Amortizacija se, kao nenovčani rashod, dodaje neto-dobiti.

budući da poduzeće može iskazivati dobit uz negativan SNTV u slučaju intenzivnih ulaganja, ili otplate dugova.

Primjena ove metodologije na financijske institucije ima dvije posebnosti. Prvo, kod financijskih institucija dug je ugrađen u srž poslovnog modela (depoziti, premijske obveze, tehničke pričuve i sl.), pa se financijske institucije vrednuju izravno kroz kapitalnu perspektivu, bez odvajanja duga od redovnih poslovnih aktivnosti – za razliku od nefinancijskih poduzeća, kod kojih se dug promatra kao vanjski izvor financiranja, odvojen od redovnog poslovanja. Drugo, regulatorni kapitalni zahtjevi su kod financijskih institucija, za razliku od diskrecijskih kapitalnih izdataka kod nefinancijskih poduzeća, obvezni, pa institucija koja ih ne ispunjava podliježe nadzornim mjerama ili čak gubitku odobrenja za rad. Na taj način regulatorni kapital postaje funkcionalni ekvivalent kapitalnih izdataka temeljem čega se može formulirati sljedeći izraz:

$$SNTV = Neto\text{-}dobit - \Delta regulatorni\ kapital. \quad (2)$$

Ako prema izrazu (2), neto-dobit premašuje prirast regulatornog kapitala, institucija generira višak novčanog tijeka spremnog za isplatu vlasnicima. U suprotnom – što je slučaj kod hrvatskih MOD-ova – negativna razlika mora biti pokrivena korištenjem vanjskog kapitala. Pritom, regulatorni kapital za MOD-ove određen je Zakonom o mirovinskim osiguravajućim društvima (ZMOD), (NN 22/14, 29/18, 115/18, 156/23, 52/25 i 13/26) kroz potrebnu granicu solventnosti (PGS):

$$PGS = (4\% \times TP) + komponenta\ rizičnog\ kapitala \quad (3)$$

gdje stopa od 4% tehničkih pričuva (namijenjena osiguranju kapitalne adekvatnosti MOD-a), prema spomenutom zakonu, ne predstavlja aktuarsku izračunatu optimalnu stopu za MOD-ove, već regulatorni standard koji osigurava da mirovinsko osiguravajuće društvo raspolaže minimalnim kapitalom razmjernim veličini svojih obveza[4]. U izrazu (3) TP označava pojam tehničke pričuve kao jedinstveni naziv za aktuarske utvrđene obveze MOD-a prema korisnicima mirovina. U financijskim izvještajima MOD-ova za 2025. godinu te se stavke, zbog usklađivanja s MSFI 17[5], iskazuju pod

[4] Stopa od 4% nije rezultat nekog konkretnog ekonomskog modela, već je preuzeta iz europskog režima solventnosti za životna osiguranja *(Solvency I)*, koji se koristi jednostavnim, fiksnim formulama vezanim uz opseg poslovanja (npr. postotak tehničkih pričuva ili premija), a bez uzimanja u obzir stvarnog rizičnog profila portfelja imovine.

[5] MSFI 17 (engl. *IFRS 17*) — Međunarodni standard financijskog izvještavanja za ugovore o osiguranju, koji je zamijenio prijelazni standard MSFI 4 uvodi mjerenje obveza iz ugovora o

nazivom *'obveze iz ugovora o mirovinama'*. Budući da obveze iz ugovora trećeg mirovinskog stupa u Hrvatskoj čine relativno malen dio ukupnih obveza, one u ovoj analizi nisu posebno izdvojene. Financijski izvještaji društava ne prikazuju zasebno komponentu rizičnog kapitala vezanu uz rizik smrti i jamstveno razdoblje u ugovorima o mirovinama[6]. Ta je komponenta ugrađena u agregatnu procjenu budućih novčanih tijekova (temeljenu na tablicama smrtnosti Državnog zavoda za statistiku), kao temelja za izračun tehničkih pričuva, koje prema čl. 79 ZMOD-a (NN 22/14, 29/18, 115/18, 156/23, 52/25 i 13/26) izravno utječu na visinu potrebne granicu solventnosti. Stoga se u ovom radu ta komponenta tretira agregatno, u sklopu ukupne tehničke pričuve, bez daljnje dekompozicije. Budući da je ta komponenta specifična za navedene mirovinske programe, za potrebe izraza (3) ona se aproksimira sljedećim izrazom:

$$PGS \approx 4\,\% \times TP. \tag{4}$$

Za slučaj realizacije sistemskih rizika – npr. globalni pad tržišta kapitala i posljedični pad vrijednost financijske imovine kao temeljnog pokrića za isplatu mirovina iz MOD-ova – regulator (HANFA[7]) uveo je dodatni osigurač, tzv. „regulatorni kapitalni prag" koji predstavlja razinu kapitala od 120% potrebne granice solventnosti. U slučaju pada razine kapitala ispod 120%, nastupa obveza MOD-a o izvještavanju regulatora, što za posljedicu može imati izradu plana oporavka, odnosno poduzimanje odgovarajućih mjera za jačanje kapitalne pozicije. Iako zahtijevani prag solventnosti od 120% ne predstavlja formalni zakonski minimum kapitala, ta razina je postavljena kao efektivno relevantan prag ispod kojega regulator može zahtijevati dodatnu dokapitalizaciju društva, kako bi jamstveni kapital došao na razinu iznad regulatornog praga. Stoga, u praksi MOD-ovi u Hrvatskoj nastoje održavati kapital iznad navedene razine. Za potrebe ove analize uvodi se i pokazatelj potrebnog prirasta kapitala (PPK), koji predstavlja prirast kapitala potreban za održavanje kapitalne pozicije na razini od 120% potrebne granice solventnosti. Uz aproksimaciju potrebne granice solventnosti s 4%

osiguranju (uključujući i tehničke pričuve) kao sadašnju vrijednost budućih novčanih tijekova, diskontiranu tržišno konzistentnom kamatnom stopom, uz eksplicitno uključenu maržu za rizik. Time se, u odnosu na stariju metodologiju, mijenja i način obračuna tehničkih pričuva, neovisno o stvarnoj promjeni portfelja obveza.

[6] Društvo mora držati dio kapitala kao rezervu za slučaj prijevremene smrti korisnika unutar jamstvenog razdoblja isplate mirovine, radi isplate preostalog iznosa zakonskim nasljednicima..

[7] Hrvatska agencija za nadzor financijskih usluga.

tehničkih pričuva, potrebni prirast kapitala (ΔPPK) iznosi 4,8% prirasta tehničkih pričuva (ΔTP), što je vidljivo iz sljedećeg izraza:

$$\Delta PPK = 4\% \times \Delta TP \times 1{,}20 = 4{,}8\% \times \Delta TP. \quad (5)$$

Zbog toga se potrebni prirast kapitala u analitičkom modelu MOD-a aproksimira s 4,8% prirasta tehničkih pričuva (5).

Uključivanjem neto-dobiti sektora umanjene za potrebni prirast kapitala (ΔPPK) uvodi se pokazatelj neto stvaranja vrijednosti sektora ($SNTV_{MOD}$), koji mjeri kapitalnu samoodrživost MOD-a, odnosno sposobnost MOD-a da financira vlastiti rast tehničkih pričuva iz interno generirane dobiti, a bez potrebe za vanjskom vlasničkom dokapitalizacijom (6):

$$SNTV_{MOD} = \text{neto-dobit} - \Delta PPK. \quad (6)$$

Budući da organska dobit MOD-a proizlazi isključivo iz naknada za upravljanje (1,5% jednokratno i 0,17% godišnje od doznake, uz maksimalni ukupni iznos od 5% doznačenih sredstava), pokazatelj $SNTV_{MOD}$ je pozitivan samo u slučaju kada je ostvarena neto-dobit veća od umnoška prirasta tehničkih pričuva i koeficijenta 0,048[8]. To znači da bi na 1 EUR prirasta tehničkih pričuva, MOD trebao zadržati dodatnih 4,8 eurocenti kapitala da bi kapitalna pozicija društva ostala na sigurnosnoj razini, odnosno 120% iznad zakonski propisanog minimuma (7):

$$\text{neto-dobit} > 0{,}048 \times \Delta TP. \quad (7)$$

Taj uvjet rijetko je ispunjen u fazi brzog rasta portfelja jer svaka novčana jedinica novog portfelja zahtijeva 0,048 jedinica novog regulatornog kapitala koji organska dobit ne može apsorbirati. Na taj način stvara se paradoks u kojemu rast tehničkih pričuva društva, koji predstavlja stratešku svrhu poslovanja, ali istodobno i javni interes, predstavlja financijski teret za vlasnike. Tako stvoren trajno negativan $SNTV_{MOD}$[9] ne znači nužno i propast

[8] Ovaj koeficijent predstavlja umnožak potrebne granice solventnosti od 4% (0,04) i koeficijenta regulatornog kapitalnog praga od 1,2 (120%) potrebne granice solventnosti.

[9] $SNTV_{MOD}$ (slobodni novčani tijek vlasnicima MOD-a) ne interpretira se u strogo računovodstvenom smislu (kao neto-dobit ili računovodstveni rezultat razdoblja), već kao pokazatelj kapitalne samoodrživosti. Prirast potrebne granice solventnosti (ΔPGS) promatra se kao funkcionalni ekvivalent regulatornog kapitala koji društvo mora osigurati radi nastavka poslovanja. Stoga pokazatelj $SNTV_{MOD}$ mjeri sposobnost MOD-a da organski generiranom dobiti financira rast regulatornih kapitalnih zahtjeva bez dodatnih kapitalnih injekcija vlasnika. Kako bi se osigurala dodatna sigurnosna margina iznad regulatornog minimuma, u financijskim projekcijama koje slijede u nastavku rada koristi se izraz za prirast potrebnog kapitala (ΔPPK = 120% × ΔPGS).

društva, koje može nastaviti normalno poslovanje, ali pod uvjetom postojanja kapaciteta i volje vlasnika za kontinuiranom dokapitalizacijom društva[10].

Ipak, takvo stanje ukazuje da nastavak poslovanja MOD-a ovisi o vanjskim odlukama vlasnika, umjesto o inherentnoj snazi poslovnog modela. Ovaj problem je krucijalan, budući da korisnici usluga MOD-ova (umirovljenici), koji su prenijeli svoja sredstva iz obveznih mirovinskih fondova, više nemaju 'opciju povratka', tj. bilo kakvih promjena.

Relevantna istraživanja na ovu temu mogu se svrstati u tri skupine, i to: teoriju regulacije kapitalnih zahtjeva, literaturu o kapitalnim zahtjevima prema mirovinskim institucijama, te metodološku literaturu o vrednovanju reguliranih financijskih institucija.

Teorijsku podlogu rada čini Merton (1974), koji Black-Scholesovu teoriju opcijskog vrednovanja primjenjuje na korporativni dug, tretirajući vlasnički kapital poduzeća kao *call*-opciju na vrijednost njegove imovine. Pritom se implicitno jamstvo vjerovnicima (korisnicima usluga) u reguliranim sustavima definira kao izvor moralnog hazarda, s obzirom da ograničena odgovornost dioničara stvara problematičnu asimetriju prema kojoj s jedne strane dioničari u potpunosti participiraju u dobiti, dok s druge strane potencijalni gubitak iznad uloženog kapitala u cijelosti snosi jamac (država, sustav osiguranja ili regulator). Ovdje spada i doprinos Stiglera (1971) čija teorija ekonomske regulacije ukazuje na mogućnost 'regulatornog zarobljavanja' – pojave u kojoj regulacija, umjesto da štiti javni interes, počinje služiti interesima same regulirane industrije. Upravo ovaj doprinos koristi se u analizi utjecaja fiksno definiranog iznosa potrebne granice solventnosti mirovinskih osiguravajućih društava (3) da bi se utvrdilo djeluje li ovo pravilo u interesu korisnika (umirovljenika) u vidu stabilnosti isplate mirovina i njihova stalnog usklađivanja sa stopama rasta cijena i stopama gospodarskog rasta, ili trajno destabilizira cjelokupni sustav mirovinskih osiguravajućih društava.

[10] Izraz "trajno" treba shvatiti uvjetno, u odnosu na promatrano i projicirano razdoblje rada (do 2030. godine), a ne kao bezuvjetnu karakteristiku poslovnog modela. Ovo obilježje proizlazi iz činjenice da će u sljedećem razdoblju tehničke pričuve sektora, uslijed priljeva novih korisnika s većom akumuliranom štednjom, rasti bržim tempom od smanjenja pričuva po postojećim korisnicima. Zbog toga se na agregatnoj razini ne očekuje značajan efekt oslobađanja kapitala po isteku isplatnog razdoblja. Ovo očekivanje temelji na demografskoj dinamici drugog mirovinskog stupa, koji je zbog svog relativno kratkog postojanja (od 2002.) tek sada ušao u fazu ubrzanog priljeva novih korisnika, a koja će očekivano potrajati sljedećih 10 – 15 godina.

Kada su mirovinska osiguravajuća društva u pitanju, više studija dokazuje da fiksne formulom definirane *(formula-based)* kapitalne zahtjeve odlikuje procikličnost i sustavna neosjetljivost na rizični profil portfelja. Antolin (2008) na panelu zemalja članica OECD-a pokazuje da pritisak zahtjeva za održavanjem kapitalnog praga kulminira upravo u razdobljima makroekonomskog pada, kada istodobni pad vrijednosti financijske imovine i porast sadašnje vrijednosti obveza najsnažnije pogađa kapitalnu poziciju mirovinskih osiguravajućih društava. Zbog toga fiksno definirana formula djeluje prociklički, umjesto stabilizirajuće.

Whitehouse (2009) pokazuje da se, unatoč zakonski propisanoj obvezi indeksacije mirovina (prema inflaciji i/ili gospodarskom rastu), u većini zemalja OECD-a ta pravila u praksi često zaobilaze upravo u razdobljima fiskalnih pritisaka, ili gospodarske stagnacije, čime zakonska obveza usklađivanja mirovinskih primitaka s inflacijom[11] postaje izvorom sistemskog rizika upravo u trenutku kada je institucijama koje isplaćuju mirovine (MOD) najteže – gospodarska stagnacija istovremeno umanjuje prinose od ulaganja imovine za pokriće tehničkih pričuva i povećava same pričuve, zbog obveze usklađivanja (povećavanja) mirovina.

Severinson i Yermo (2012) pokazuju da formulom definirani zahtjevi solventnosti djeluju asimetrično ovisno o tržišnom ciklusu. U fazi gospodarskog pada može, radi udovoljavanja kapitalnim zahtjevima regulatora, doći do povećane prodaje rizičnije imovine (npr. dionica), čime se neizbježno pojačava prociklički (nepovoljni) pritisak na tržišta. Pritom, valja naglasiti da standardizirani kapitalni zahtjevi ne prate uvijek stvarni rizik pojedine imovine, pa institucije s manje kapitalnog viška biraju manje rizičnu imovinu s nižim prinosom (npr. državne obveznice), umjesto potencijalno isplativije imovine (npr. dionice), a na štetu dugoročnih interesa korisnika.

Impavido i Rocha (2006), na primjeru Mađarske i njezina drugog mirovinskog stupa, te Antolin i Stewart (2009), u pregledu reakcija ekonomske politike na financijsku krizu (2008) u tranzicijskim zemljama istočne Europe i širem krugu zemalja OECD-a, pokazuju da su sustavi kapitalizirane štednje (poput hrvatskoga drugog i trećeg mirovinskog stupa) osjetljivi na tržišne i kamatne šokove koji se u fazi isplate neizbježno prenose na institucije zadužene za isplatu mirovina. Ovu ranjivost potvrđuje i hrvatsko iskustvo iz 2022. godine, kada su, zbog naglog rasta kamatnih stopa i

[11] Slično odredbama hrvatskog Zakona o mirovinskim osiguravajućim društvima (NN 22/14, 29/18, 115/18, 156/23, 52/25 i 13/26).

posljedičnog pada vrijednosti obveznica, sve tri rizične kategorije (A, B, C) obveznih mirovinskih fondova zabilježile negativne prinose, pri čemu je upravo najkonzervativnija kategorija ulaganja (C), namijenjena osiguranicima neposredno pred odlazak u mirovinu, ostvarila najveći pad (5,3%), zbog svoje visoke izloženosti obveznicama, odnosno kamatnom riziku.

Na tom tragu i Barr i Diamond (2008) naglašavaju nestabilnost fiksnih formula za određivanje praga solventnosti u inflacijskim epizodama, ukazujući indirektno na slabosti europskoga regulatornog okvira *Solvency I*[12]. Blake (2006) dodaje da tržišna cijena opcije dugovječnosti koju MOD preuzima od osiguranika izravno utječe na potrebnu razinu kapitalnih rezervi, jer sa skupljom opcijom, MOD treba izdvojiti više kapitala za pokriće rizika isplate (mirovinske) rente, tijekom razdoblja dužeg od planiranog.

Metodološki okvir rada oslanja se na doprinose Damodarana (2012, 2022), koji regulatorni kapital tretira kao funkcionalni ekvivalent kapitalnih izdataka, kao i na spoznaje Kollera, Goedharta i Wesselsa (2010) o hibridnoj prirodi tehničkih pričuva. Osim toga, rad se referira i na zaključke Pennacchija i Rastada (2011), koji na primjeru javnih mirovinskih fondova u SAD-u pokazuju da negativni, regulatorno uzrokovan slobodni novčani tijek vlasnicima (SNTV) ne implicira nužno nesolventnost društva, ali signalizira stalnu ovisnost o vanjskom kapitalu.

Empirijska literatura hrvatskih autora o kapitalnoj održivosti mirovinskih osiguravajućih društava još uvijek je relativno skromna, pa tako Vukorepa (2015) te Nestić, Potočnjak, Puljiz, Rašić Bakarić, Švaljek, Tomić, Vehovec i Vukorepa (2011) razmatraju normativne aspekte drugog i trećeg mirovinskog stupa u Hrvatskoj, no bez kvantitativne analize financijskog položaja mirovinskih osiguravajućih društava. Bežovan (2019) kritički evaluira ishode uvođenja drugog mirovinskog stupa, ukazujući da tranzicijski trošak formiranja drugog stupa premašuje ostvarene prinose obveznih

[12] *Solvency I* predstavlja prijašnji regulatorni okvir EU (do 2016.) za kapitalne zahtjeve osiguravatelja, temeljen na jednostavnim, fiksnim formulama vezanima uz opseg poslovanja (npr. postotak tehničkih pričuva ili premija), a bez osjetljivosti na stvarni rizični profil portfelja imovine. Nakon njega uslijedio je novi regulatorni okvir *Solvency II*, uveden upravo zbog tih ograničenja – formule neosjetljive na stvarni rizični profil portfelja i nesposobnosti prilagodbe promjenama novim tržišnim i/ili demografskim uvjetima poput inflacije i/ili rasta životnog vijeka. Stoga, prema *Solvency II* kapitalni zahtjev se izračunava na temelju stvarne izloženosti riziku, umjesto prema paušalno određenim postocima premija i pričuva, čime je barem konceptualno otklonjena slabost koju kritiziraju Barr i Diamond (2008.) – statičnost formule koja ne prati promjenu temeljnih parametara rizika.

mirovinskih fondova, dok Bejaković (2019) brani opravdanost zadržavanja kapitalizirane mirovinske štednje naglašavajući rizik njezina napuštanja na povjerenje u sustav i mirovinsku reformu u cjelini. Samodol (2020) dodatno dokumentira ubrzanu dinamiku priljeva umirovljenika u sustav u razdoblju nakon 2009. godine, koja izravno utječe na obujam sredstava transferiranih prema MOD-ovima, a time i na ozbiljnost problema kojega ovaj rad analizira[13].

## 3. REGULATORNI I INSTITUCIONALNI OKVIR

Djelatnost hrvatskih MOD-ova regulirana je Zakonom o mirovinskim osiguravajućim društvima, (NN 22/14, 29/18, 115/18, 156/23, 52/25 i 13/26), pri čemu u Hrvatskoj trenutno posluju dva MOD-a[14], pod izravnim nadzorom regulatora (HANFA). Spomenuti Zakon definira potrebnu granicu solventnosti, kao regulatorno utvrđenu minimalnu razinu kapitalne adekvatnosti mirovinskih osiguravajućih društava od 120%, koja se mora pokrivati putem odgovarajućeg jamstvenog kapitala. Ovaj mehanizam je automatski i razmjeran, što znači da s prestankom uplata mirovinskog obveznika u obvezni mirovinski fond i transferom akumuliranih sredstava s njegova računa u jedan od dva MOD-a, u odabranom MOD-u rastu potrebe za povećanjem tehničke pričuve za aktuarsku sadašnju vrijednost budućih obveza. Time se povećava potrebna granicu solventnosti MOD-a za približno 4% vrijednosti prirasta tehničkih pričuva, što dalje zahtijeva potrebni prirast kapitala u iznosu od 4,8% rasta tehničkih pričuva. Budući da su opisane promjene zakonski definirane za svakog novog umirovljenika, koji prestankom statusa obveznika doprinosa (drugi mirovinski stup) prelazi u status korisnika mirovine (ulazak u MOD), sektor mirovinskih osiguravajućih društava nema nikakav utjecaj na ovaj automatizam koji značajno utječe na njihovo poslovanje.

Naknada za upravljanje mirovinskim osiguravajućim društvima (čl. 29.-30., ZMOD) sastoji se od jednokratne naknade u visini od 1,5% vrijednosti

[13] Redovita publikacija HANFA-e 'Financijska stabilnost' (2021. – 2023.) prati sistemske rizike sektora mirovinskih fondova i mirovinskih osiguravajućih društava u okviru šireg nadzora nad financijskim sektorom, no bez posebnog fokusa na kapitalnu održivost poslovnog modela MOD-ova. Upravo tu prazninu – nedostatak kvantitativne analize financijskog položaja i kapitalne samoodrživosti MOD-ova kao specifične institucionalne kategorije – ovaj rad izravno adresira.

[14] Raiffeisen mirovinsko osiguravajuće društvo d.d. (RMOD, osnovano 2002.) i Hrvatsko mirovinsko osiguravajuće društvo (HRMOD, osnovano 2020.).

doznake prilikom prijenosa sredstava iz drugog mirovinskog stupa te godišnje naknade od 0,17% vrijednosti doznake obračunate na izvorni, a ne na tržišni iznos. Pritom, ukupni iznos naknade zakonski je ograničen na 5% vrijednosti doznake, što znači da se pri godišnjoj stopi od 0,17%, taj ukupni iznos naknade dostiže tek nakon 19 godina mirovinskih isplata, što predstavlja razdoblje tek nešto kraće od prosječnog životnog vijeka korisnika u mirovni koji u Hrvatskoj iznosi 22 godine[15]. U slučaju pada omjera jamstvenog kapitala i potrebne granice solventnosti ispod 120%, regulator (HANFA) može reagirati tražeći od MOD-a plan sanacije, ograničavanje raspodjele dobiti, ili u krajnjem slučaju oduzeti odobrenje za rad. Nadzorni okvir u kojemu djeluje HANFA usklađen je s načelom razmjernosti direktive *IORP II*[16], no hrvatski MOD-ovi nemaju instituciju izravno usporedivu s onom u EU[17].

U hrvatskoj praksi MOD-ovi u institucionalnom smislu premošćuju drugi i prvi mirovinski stup, budući da preuzimaju rizik dugovječnosti koji se u prvom stupu, tj. sustavu međugeneracijske solidarnosti *(PAYG)* kolektivno (intergeneracijski) raspoređuje. Bez ovako zamišljenih MOD-ova hrvatski osiguranici u drugom stupu ne bi mogli pretvoriti svoju akumuliranu štednju u doživotnu (mirovinsku) rentu, zbog čega financijska održivost MOD-ova nadilazi pitanje samih korporativnih financija. Izmjene Zakona o mirovinskim osiguravajućim društvima (NN 156/23) uvele su prijelaz s MSFI 4 na MSFI 17[18], što je uzrokovalo metodološki diskontinuitet u iskazivanju tehničkih pričuva, a time i promjenu potrebne granice solventnosti (ΔPGS), čiji smjer i intenzitet ovisi o strukturi portfelja pojedinog društva. Pravilnik o adekvatnosti kapitala (NN 74/14) i Pravilnik o minimalnim standardima obračuna tehničkih pričuva (NN 20/24) propisuju izračun granica

[15] Prema podacima Hrvatskog zavoda za mirovinsko osiguranje (HZMO) prosječno razdoblje korištenja mirovine iznosi 22 godine (muškarci 19 godina, a žene 26 godina).

[16] *IORP II* — Direktiva (EU) 2016/2341 o djelatnostima i nadzoru institucija za strukovne mirovine, koja uređuje standarde upravljanja i solventnosti uz naglasak na proporcionalnost nadzora prema veličini i složenosti institucije.

[17] Slične kapitalne izazove za doživotne mirovinske isplate, australski i britanski regulatori rješavaju tako što kapitalni zahtjev za doživotne anuitete povezuju sa stvarnom ročnošću i likvidnošću portfelja imovine, umjesto s paušalnom formulom.

[18] MSFI 17 (engl. *IFRS 17*) — Međunarodni standard financijskog izvještavanja za ugovore o osiguranju, koji je zamijenio prijelazni standard MSFI 4. MSFI 17 uvodi mjerenje obveza iz ugovora o osiguranju (uključujući i tehničke pričuve) kao sadašnju vrijednost budućih novčanih tijekova diskontiranu tržišno konzistentnom kamatnom stopom, uz eksplicitnu maržu za rizik. Time se, u odnosu na stariju metodologiju, (MSFI 4) mijenja i način obračuna tehničkih pričuva, neovisno o stvarnoj promjeni portfelja obveza.

solventnosti, prihvatljivu imovinu za pokriće potrebne granice solventnosti te aktuarske pretpostavke (diskontnu stopu, tablice preživljavanja) koje posredno određuju razinu potrebne granice solventnosti.

Dodatni kapitalni pritisak na MOD-ove u Hrvatskoj predstavlja generacija osiguranika koja od početka mirovinske reforme (2002.) uplaćuju doprinose u drugi mirovinski stup. Ona postupno dostiže dob odlaska u mirovinu, zbog čega se tijekom cijeloga idućeg desetljeća očekuje povećani val transfera iz obveznih mirovinskih fondova u mirovinska osiguravajuća društva. Taj 'priljev' sredstava novih umirovljenika, koji bi u drugim okolnostima trebao biti povoljan za sektor (rast obujma poslovanja i prihoda) u ovom slučaju paradoksalno povećava potrebu za kapitalom vlasnika. Svaka nova preuzeta obveza (novi ugovor o mirovini) prema Zakonu zahtijeva razmjerno povećanje potrebne granice solventnosti (PGS), koju MOD mora pokriti vlastitim sredstvima, neovisno o tome što se istovremeno povećava i imovina za pokriće tehničkih pričuva.

## 4. EMPIRIJSKA ANALIZA

Prije prikaza agregatnih podataka za hrvatske MOD-ove valja pojasniti temeljni sistemski problem s kojim se oni suočavaju, a koji negativni slobodni novčani tijek ($SNTV_{MOD}$) čini stalno prisutnim strukturalnim problemom, a ne slučajnom i prolaznom pojavom. Prilikom transfera akumuliranog iznosa iz obveznoga mirovinskog fonda u mirovinsko osiguravajuće društvo (odlazak pojedinca u mirovinu), MOD ostvaruje prihode poslovanja iz dva novčana tijeka – jednokratnu naknadu u visini 1,5% vrijednosti transfera i godišnju naknadu u visini 0,17% tog istog transfera. Budući da se jednokratna naknada odbija od vrijednosti ukupnog transfera prije ulaska preostalog iznosa transfera u tehničku pričuvu, prirast tehničke pričuve iznosi približno 98,5% vrijednosti transfera iz drugog mirovinskog stupa. Primjenom izraza (5) kod kojega stopa od 4,8% predstavlja umnožak potrebne granice solventnosti (4%) i regulatornog kapitalnog praga (120%) dobiva se izraz za prirast potrebnog kapitalnog praga MOD-a po svakom novom korisniku:

$$\Delta PPK = 4{,}8\% \times (98{,}5\% \times P) = 4{,}73\% \times P \quad (8)$$

gdje P predstavlja inicijalni iznos transfera iz drugog mirovinskog stupa. Drugim riječima, od svakog eura doznake koji iz obveznoga mirovinskog fonda uđe u portfelj MOD-a, približno 4,73 eurocenta odmah se pretvara u novi kapitalni zahtjev, dok jednokratna naknada MOD-a za taj isti euro iznosi

svega 1,5 eurocenta. Na taj se način stvara neposredni kapitalni manjak od 3,23 eurocenta po svakom euru doznake, dok se godišnja naknada akumulira presporo da bi nastali deficit pokrila unutar prihvatljivog kraćeg razdoblja. Tablica 1. ilustrira opisanu dekompoziciju na primjeru doznake od 100.000 EUR[19].

**Tablica 1. Dekompozicija slobodnog novčanog tijeka hrvatskog MOD-a na primjeru doznake od 100.000 EUR**

| **Stavka** | **Iznos** *(EUR)* | **Iznos** *(% doznake)* |
|---|---|---|
| jednokratna naknada MOD-a (1,5%) | 1.500 | 1,50 |
| godišnja naknada* (0,17%, fiksni iznos) | 170 | 0,17 |
| potrebni prirast kapitala (ΔPPK) (4% × 98.500 × 1,20) | −4.728 | −4,73 |
| slobodni novčani tijek ($SNTV_{MOD}$) u godini transfera | −3.058 | −3,06 |
| slobodni novčani tijek ($SNTV_{MOD}$) u svakoj sljedećoj godini isplate mirovine (iznos godišnje naknade od 0,17% obračunat na inicijalni iznos prenesen iz drugog mirovinskog stupa) | +170 | +0,17 |
| kumulativno stanje slobodnog novčanog tijeka ($SNTV_{MOD}$) tijekom 15 godina (negativno) | −678 | −0,68 |
| kumulativno stanje slobodnog novčanog tijeka ($SNTV_{MOD}$) tijekom 19 godina (točka pokrića) | +2 | 0,00 |
| kumulativno stanje slobodnog novčanog tijeka ($SNTV_{MOD}$) tijekom 20 godina (pozitivno) | +172 | +0,17 |

* Godišnja naknada obračunava se tijekom cijelog razdoblja mirovinskih isplata na inicijalno primljenu doznaku (100.000 EUR), a prema čl. 92. ZMOD-a.

Izvor: Izračun autora prema ZMOD (NN 22/14, 29/18, 115/18, 156/23, 52/25 i 13/26).

Tablica 1. prikazuje kako ukupna naknada koju MOD naplaćuje u iznosu od 1,67% (1,5% jednokratno i 0,17% godišnje) osjetno zaostaje za regulatornim kapitalnim zahtjevom od 4,73% visine doznake, zbog čega svaki novi korisnik MOD-a (novi umirovljenik) već u prvoj godini, transferom sredstava

[19] Budući da ovaj primjer ne uključuje operativne troškove poslovanja, stvarni novčani tijek bio bi još niži, stvarajući na taj način još veći poslovni deficit za MOD.

iz obveznoga mirovinskog fonda, generira neposredni kapitalni manjak od 3,06% vrijednosti doznake koji mora pokriti vlasnik MOD-a. Budući da se taj manjak, uz godišnju naknadu MOD-a od 0,17%, nominalno i bez diskontiranja nadoknađuje tek u 19. godini od transfera sredstava – kada kumulativni novčani tijek prvi put prelazi iz negativnog u (tek simbolično) pozitivni, a tek od 20. godine postaje trajno pozitivan – pokazuje se da predviđene naknade za poslovanje MOD-a strukturno nisu dovoljne da u razumnom roku pokriju inicijalni kapitalni izdatak[20]. Na taj način svaki novi umirovljenik (član MOD-a) postaje u financijskom smislu neto-kapitalni konzument, i to kako u godini transfera sredstava, tako i kumulativno tijekom standardnoga aktuarskog razdoblja isplate. Zbog toga se stvara paradoksalna situacija u kojoj rast portfelja — temeljna svrha MOD-a i javni interes drugog mirovinskog stupa — istodobno generira strukturnu potrebu za dodatnim kapitalom vlasnika. Za razliku od fenomena *new business strain*[21] u životnom osiguranju (Koller et al., 2010), gdje se početno kapitalno opterećenje s vremenom amortizira kroz buduće novčane tijekove, kod MOD-ova ono poprima trajni karakter jer novi korisnici ostaju neto-kapitalni konzumenti tijekom čitavog promatranog razdoblja.

Tablica 2. prikazuje agregatne podatke sektora hrvatskih MOD-ova za razdoblje 2020. – 2025., a prema revidiranim godišnjim financijskim izvještajima društava[22]. Povijesni $SNTV_{MOD}$ je izračunat kao razlika između neto-dobiti i prirasta potrebne granice solventnosti (ΔPGS), dok se vrijednost pokazatelja 'potrebni prirast kapitala' (PPK) koristi u projekcijskom modelu, a implicirana dokapitalizacija prikazuje kao promjena ukupnoga jamstvenog kapitala umanjena za neto-dobit. Indeks potrošačkih cijena (IPC) predstavlja stopu inflacije.

[20] Gornja tablica daje pojednostavnjeni prikaz novčanog tijeka pojedinačnog korisnika, i radi preglednosti i jednostavnosti praćenja ne uključuje postupno smanjenje potrebnog kapitala (ΔPPK) koje bi proizlazilo iz pada tehničke pričuve tog korisnika tijekom isplatnog razdoblja. Na razini pojedinačnog ugovora taj bi efekt pomaknuo točku pokrića na raniju godinu, no na agregatnoj (sektorskoj) razini prikazanoj u sljedećim tablicama to ne mijenja zaključke jer priljev novih korisnika s rastućim prosječnim iznosom doznake u promatranom i projiciranom razdoblju premašuje postupno smanjivanje kapitalnih zahtjeva za postojeće korisnike.

[21] *New business strain* ("kapitalno opterećenje od novog poslovanja") predstavlja pojam iz aktuarske teorije i teorije životnog osiguranja koji opisuje privremeni, ali intenzivan negativan utjecaj novog poslovanja na kapitalnu poziciju osiguravatelja u trenutku njegova nastanka.

[22] Za razdoblje 2020. – 2022. podaci su preračunati iz HRK u EUR prema službenom deviznom tečaju konverzije od 7,53450 HRK/EUR.

**Tablica 2. Agregatni kapitalni pokazatelji hrvatskog sektora MOD-a, 2020. – 2025.***

| Godina | Stopa inflacije *(%)* | Tehničke pričuve sektora *(mil. EUR)* | Potrebna granica solventnosti *(mil. EUR)* | Jamstveni kapital *(mil. EUR)* | Neto-dobit *(mil. EUR)* | Slobodni novčani tijek vlasnicima *(mil. EUR)* | Omjer jamstvenog kapitala i potrebne granice solventnosti *(%)* | Implicirana dokapitalizacija *(mil. EUR)* | Implicirana dokapitalizacija – kumulativ *(mil. EUR)* |
|---|---|---|---|---|---|---|---|---|---|
| 2020. | 0,0 | 158,09 | 5,96 | 13,46 | 1,18 | n/p | 226 | n/p | n/p |
| 2021. | 2,7 | 238,94 | 9,20 | 14,08 | 0,57 | −2,67 | 153 | 0,03 | 0,03 |
| 2022.** | 10,7 | 330,44 | 13,07 | 22,20 | −10,95 | −14,82 | 170 | 19,07 | 19,11 |
| 2023. | 8,4 | 381,15 | 13,37 | 19,78 | 1,83 | 1,53 | 148 | −4,26 | 14,85 |
| 2024. | 4,5 | 489,08 | 17,43 | 21,77 | 1,90 | −2,16 | 125 | 0,10 | 14,95 |
| 2025.** | 3,2 | 612,49 | 21,71 | 40,92 | 1,26 | −3,02 | 188 | 17,89 | 32,84 |

* Vrijednosti potrebne granice solventnosti predstavljaju stvarno iskazane regulatorne vrijednosti preuzete iz financijskih izvještaja MOD-ova. Te vrijednosti izračunate su prema čl. 79 ZMOD-a, te nisu naknadno procijenjene od strane autora primjenom pojednostavnjene formule od 4% računovodstveno iskazanih tehničkih pričuva (uobičajena aproksimacija kada stvarni regulatorni podaci nisu dostupni) Razlike između ovih dvaju pristupa proizlaze iz: a) regulatorne osnovice za obračun potrebne granice solventnosti prema ZMOD-u, koja se odvojeno računa za obvezno i dobrovoljno mirovinsko osiguranje uz dodatne rizične faktore, i b) metodoloških razlika između regulatorne i računovodstvene (MSFI 17) osnovice za iskazivanje tehničkih pričuva.

** Godine 2022. nastupila su inflacijska usklađenja mirovina i pad tržišta kapitala. Godine 2025. nastupila je integracija interventnih pričuva i dokapitalizacija MOD-ova.
Izvor: Izračun autora prema godišnjim financijskim izvještajima RMOD (2019. – 2025.) i HRMOD (2020. – 2025.).

Agregatni pokazatelji u tablici 2. pružaju snažnu empirijsku potporu hipotezi H1 prema kojoj aktualni poslovni model hrvatskih MOD-ova pokazuje ozbiljna ograničenja organske samoodrživosti cjelokupnog sektora. Kumulativna vrijednost slobodnog novčanog tijeka ($SNTV_{MOD}$) za razdoblje 2021. – 2025. iznosi negativnih 21,1 mil. EUR, uz potrebnu impliciranu dokapitalizaciju od 32,8 mil. EUR, što pokazuje da u promatranom razdoblju ostvarena neto-dobit sektora nije bila dostatna za financiranje rasta regulatorno zahtijevanog kapitala iz internih izvora. Pozitivan $SNTV_{MOD}$ ostvaren je samo u 2023. godini (1,5 mil. EUR), djelomično zbog akumuliranog rasta prihoda od godišnje naknade na sve veće stanje tehničkih pričuva, a djelomično i zbog prijelaza na nova regulatorna pravila izvještavanja (MSFI 17), koji je unio metodološki diskontinuitet u

usporedivost potrebne granice solventnosti s prethodnim razdobljima[23]. Zbog toga rezultat za 2023. godinu treba tumačiti s oprezom, budući da dio pozitivnog učinka može proizlaziti iz promjene metodologije, a ne isključivo iz stvarnog poboljšanja poslovanja. U svim ostalim godinama, održavanje kapitalne adekvatnosti bilo je moguće jedino uz dodatna ulaganja vlasnika.

Ovaj nalaz potvrđuje i kretanje omjera jamstvenog kapitala i potrebne granice solventnosti koji se smanjio s 226% u 2020. godini na 125% u 2024. godini, što ujedno predstavlja najnižu vrijednost u promatranom razdoblju, a koja se nalazi vrlo blizu regulatornog praga upozorenja od 120%. Sektor se time u 2024. godini približio granici regulatorne intervencije unatoč pozitivnom poslovnom rezultatu, što upućuje na zaključak da zahvaljujući postojećem regulatornom okviru s rastom obujma poslovanja pozicija mirovinskih osiguravajućih društava ne jača, već se upravo suprotno, iscrpljuje.

Godina 2022. predstavlja najizraženiji empirijski primjer osjetljivosti sektora na inflacijski šok kada su djelovala dva čimbenika. Prvi je bilo zakonsko usklađenje mirovina sa stopom inflacije (2,6% i 5,9%), čime su povećane tehničke pričuve, dok je drugi bio pad tržišne vrijednosti dužničkog portfelja uslijed rasta kamatnih stopa, što je dovelo do ukupnog rasta realiziranih i nerealiziranih gubitaka do iznosa od oko 12 mil. EUR. Kombinirani učinak obaju čimbenika rezultirao je negativnim $SNTV_{MOD}$ od 14,8 mil. EUR te neizbježnom dokapitalizacijom sektora od oko 19 mil. EUR unutar jedne godine. Pritom, ovaj poslovni stres nije bio idiosinkratski, ograničen na pojedino društvo, već je imao sistemski karakter, pogodivši istodobno čitav sektor. Ovaj nalaz upućuje na strukturnu ranjivost MOD-ova na kombinaciju inflacijskog i kamatnog rizika — ranjivost koja proizlazi iz same prirode njihova poslovnog modela (indeksirane obveze uz dužnički portfelj osjetljiv na promjenu kamatnih stopa) i koja nije ovisila o veličini pojedinog društva niti o priljevu sredstava iz drugog stupa. Pritom, posebno je zabrinjavajuće da kumulativni iznos implicitnih dokapitalizacija sektora (32,8 mil. EUR) premašuje njegov ukupni jamstveni kapital na početku promatranog razdoblja (13,46 mil. EUR, 2020.) za gotovo 2,4 puta. Međutim, budući da ovaj iznos uključuje i negotovinsku komponentu vezanu uz promjenu vrijednosti interventnih pričuva, relevantnija je usporedba temeljena na iznosu koji odražava stvarnu gotovinsku potrebu za dokapitalizacijom — 18,9 mil. EUR. I ova, konzervativnija, procjena predstavlja oko 140% jamstvenog kapitala

[23] Detaljnija metodološka rasprava o učinku uvođenja MSFI 17 na izračun potrebne granice solventnosti prelazi okvire ovog rada.

sektora na početku razdoblja, čime se, neovisno o metodološkom pristupu, potvrđuje da sektor nije bio u stanju financirati rast regulatornih kapitalnih zahtjeva isključivo iz interno generirane dobiti, te da bi bez kontinuirane potpore vlasnika održavanje propisane kapitalne adekvatnosti bilo ozbiljno dovedeno u pitanje. Razlika između bruto (32,8 mil. EUR) i korigiranog (18,9 mil. EUR) iznosa pritom sama po sebi ukazuje na to koliki je dio ukupnoga kapitalnog opterećenja sektora posljedica računovodstvenih, a koliki stvarnih, gotovinskih zahtjeva vlasnika za unosom svježeg kapitala.

Ipak, valja reći da negativni slobodni novčani tijek (SNTV) nije neuobičajena pojava među financijskim institucijama u fazi njihova intenzivnog rasta. Banke koje ubrzano povećavaju kreditni portfelj, ili osiguravatelji koji snažno povećavaju premijski prihod često moraju povećavati regulatorni kapital brže od računovodstvene dobiti. U takvim okolnostima negativni SNTV predstavlja posljedicu rasta, a ne nužno znak poslovne slabosti. Međutim, hrvatski se MOD-ovi, kao novi oblik financijsko-isplatnih institucija, razlikuju od većine već postojećih financijskih institucija na tržištu, između ostalog i po stupnju regulatorne ograničenosti poslovnog modela. Tako npr. banke mogu povećavati kamatne marže, uvoditi nove proizvode, mijenjati strukturu aktive, ili prilagođavati naknade za pružene usluge, dok osiguravatelji mogu prilagođavati premije i preuzimati različite profile rizika. U isto vrijeme MOD-ovi raspolažu znatno užim skupom instrumenata – naknade za njihove usluge su zakonski ograničene, struktura proizvoda (usluga) je unaprijed definirana, a priljev korisnika proizlazi iz zakonskog okvira drugog mirovinskog stupa. Posljedično, negativni SNTV kod MOD-ova ima drukčiju ekonomsku interpretaciju od negativnog SNTV tipičnih rastućih financijskih institucija. U slučaju mirovinskih osiguravajućih društava on ne predstavlja samo posljedicu poslovnog rasta, već ukazuje na problem bržeg rasta regulatornih zahtjeva od mogućnosti sektora da organskim poslovanjem generira kapital. Upravo zbog toga $SNTV_{MOD}$ u ovom radu služi kao indikator organske samoodrživosti regulatornog modela, a ne kao pokazatelj solventnosti pojedinog društva.

Promjene jamstvenog kapitala sektora mogu se rastaviti na tri komponente – (1) ostvarenu neto-dobit, (2) promjene tehničkih pričuva koje utječu na potrebnu granicu solventnosti i (3) dokapitalizacije vlasnika, kao što je prikazano u tablici 3.

## Tablica 3. Dekompozicija promjene jamstvenog kapitala hrvatskog sektora MOD-a, 2021. – 2025.

| Godina | Prirast jamstvenog kapitala (JK) *(mil. EUR)* | Dio prirasta jamstvenog kapitala pokriven iz neto-dobiti *(mil. EUR)* | Dio prirasta jamstvenog kapitala pokriven iz implicirane dokapitalizacije *(mil. EUR)* | Prirast potrebne granice solventnosti *(mil. EUR)* | Prirast tehničkih pričuva *(mil. EUR)* | Pokrivenost prirasta potrebne granice solventnosti (ΔPGS) ostvarenom neto-dobiti *(%)* | Napomena |
|---|---|---|---|---|---|---|---|
| 2021. | 0,62 | 0,59 | 0,03 | 3,23 | 80,85 | 18 | dobit pokriva 18% ΔPGS* |
| 2022. | 8,12 | −10,95 | 19,07 | 3,87 | 91,50 | -283 | gubitak koji vlasnici nadoknađuju dokapitalizacijom |
| 2023. | −2,45 | 1,83 | −4,28 | 0,31* | 50,71 | 599 | dobit premašuje ΔPGS; potreba za JK** pada |
| 2024. | 1,99 | 1,89 | 0,10 | 4,05 | 107,93 | 47 | dobit pokriva 47% ΔPGS |
| 2025. | 19,15 | 1,26 | 17,89 | 4,29 | 123,41 | 29 | integracija interventnih pričuva*** i dokapitalizacije |

* Niža iskazana vrijednost potrebne granice solventnosti u 2023., u odnosu na ostale godine, podudara se s prijelazom na MSFI 17, što je utjecalo na promjenu regulatorne/računovodstvene osnovice za obračun tehničkih pričuva.

** Promjena potrebne granice solventnosti.

*** Interventne pričuve predstavljaju zasebnu kapitalnu rezervu koja se formira jednokratno sa prijenosom ranije uplaćenih sredstava vlasnika. Od 2023. godine taj višak kapitala se knjiži se kao rashod u računu dobiti i gubitka, čime se umjetno smanjuje neto-dobit i uvećava jamstveni kapital.

Izvor: Izračun autora prema godišnjim financijskim izvještajima RMOD (2019. – 2025.) i HRMOD (2020. – 2025.)

Tablica 3. prikazuje dekompoziciju promjena jamstvenog kapitala hrvatskog sektora MOD-a tijekom razdoblja 2021. – 2025., te omogućava razlučivanje doprinosa ostvarene neto-dobiti, implicitnih dokapitalizacija i promjena potrebne granice solventnosti (ΔPGS). Kumulativni rezultati za promatrano petogodišnje razdoblje pokazuju da je ukupni prirast jamstvenog kapitala sektora (27,5 mil. EUR) u cijelosti, i to u iznosu koji premašuje 100% tog prirasta (točnije 119,6%, odnosno 32,8 mil. EUR), financiran kapitalnim ulaganjima vlasnika, dok je kumulativni doprinos zadržane dobiti u istom razdoblju bio negativan (-5,4 mil. EUR). Drugim riječima, sektor u promatranom razdoblju nije ostvario internu neto- akumulaciju kapitala kroz redovito poslovanje. Pritom, vlasnička dokapitalizacija nije samo nadopunjavala rast kapitala nego je istodobno kompenzirala i kumulativni gubitak iz poslovanja. Stoga, može se konstatirati da se rast jamstvenog kapitala sektora u cijelosti temeljio na eksternim izvorima kapitala, umjesto na internoj profitabilnosti poslovanja.

Valja, međutim, napomenuti da iskazani iznos kumulativne dokapitalizacije (32,8 mil. EUR) nije u potpunosti izraz stvarnih novih kapitalnih uplata vlasnika. Oba hrvatska MOD-a su u 2025. godini formirali interventne pričuve (ukupno 13,9 mil. EUR[24]), ali samo na temelju jednokratne zakonske odredbe prema kojoj su društva stekla pravo prenijeti na račun interventnih pričuva ona sredstva koja su u razdoblju od 24 mjeseca prije stupanja na snagu prethodne izmjene ZMOD-a (NN 156/23, na snazi od 27. 12. 2023.) bila uplaćena radi pokrivanja ili sprječavanja manjka imovine za pokriće tehničkih pričuva, a koja u međuvremenu više ne služe toj svrsi. Drugim riječima, riječ je o preknjižavanju već postojećih sredstava u novu regulatornu kategoriju, a ne nužno o dodatnom, novom kapitalnom ulaganju vlasnika. Sličnu intervenciju nije moguće očekivati u budućnosti, bez novih zakonskih izmjena. Na taj način formula implicirane dokapitalizacije (porast jamstvenog kapitala umanjen za neto-dobit) sadrži negotovinski element od 13,9 mil. EUR. Zato je stvarna implicirana dokapitalizacija sektora u 2025. godini iznosila približno 3,9 mil. EUR, umjesto iskazanih 17,9 mil. EUR. Isključi li se taj učinak, kumulativna dokapitalizacija za cijelo razdoblje 2021. – 2025. opada s 32,8 na približno 18,8 mil. EUR.

[24] RMOD je formirao pričuve u visini od 10,9 mil. EUR, dok su pričuve HRMOD-a formirane na razini 3,1 mil. EUR, a prema Zakonu o izmjenama i dopunama Zakona o mirovinskim osiguravajućim društvima (NN 55/25) koji je dopustio prijenos ranije uplaćenih sredstava vlasnika u svrhu pokrivanja manjka tehničkih pričuva (ako predviđeni rizik više ne postoji) na posebni račun interventnih pričuva.

Analiza omjera neto-dobiti i promjene potrebne granice solventnosti (pokrivenost dobiti) dodatno potvrđuje ograničenu sposobnost sektora da organski financira rast kapitalnih zahtjeva. U većini promatranih godina ostvarena neto-dobit pokrivala je 20-50% povećanja potrebne granice solventnosti, dok potpuna pokrivenost nije ostvarena niti u jednoj godini. Iznimku predstavlja 2023. godina, u kojoj ostvarena neto-dobit višestruko premašuje potrebnu granicu solventnosti. Međutim, taj rezultat treba tumačiti s oprezom, budući da dijelom predstavlja posljedicu metodološkog diskontinuiteta povezanog s prelaskom na MSFI 17. Novi računovodstveni standard privremeno je smanjio iznos izračunate potrebne granice solventnosti, jer je, umjesto ranije zaključene stope (kod sklapanja ugovora), uveo tržišno konzistentnu diskontnu stopu za mirovinske obveze. Stoga je rast tržišnih kamatnih stopa u 2022. – 2023. smanjio sadašnju vrijednost tehničkih pričuva, a time i potrebnu granicu solventnosti, premda se broj korisnika MOD-a nije bitno promijenio.

Promatrano na razini analiziranog razdoblja, tehničke pričuve predstavljaju dominantan čimbenik povećanja kapitalnih zahtjeva. Njihova vrijednost povećala se s približno 158 mil. EUR u 2020. godini na oko 612 mil. EUR u 2025. godini, odnosno gotovo četiri puta, dok ostvarena profitabilnost nije pratila taj intenzitet rasta. U isto vrijeme, kumulativna neto-dobit sektora tijekom promatranog razdoblja bila je negativna i iznosila 5,4 mil. EUR, što upućuje na zaključak da interno generirana sredstva nisu bila dostatna za financiranje povećanih kapitalnih potreba. Posljedično, održavanje odgovarajuće razine jamstvenog kapitala u znatnoj je mjeri ovisilo o dodatnim kapitalnim ulaganjima. Navedeni rezultati ukazuju da rast tehničkih pričuva, kroz povećanje potrebne granice solventnosti, predstavlja jedan od ključnih čimbenika povećanih kapitalnih potreba sektora.

## 5. PROJEKCIJE KAPITALNIH POTREBA U RAZDOBLJU 2026. – 2030.

U projiciranom razdoblju sektor MOD-ova suočit će se s ubrzanim rastom priljeva sredstava iz drugog mirovinskog stupa. Rast broja osiguranika koji su u drugi mirovinski stup ušli sa njegovim osnutkom 2002. godine postupno navršava zakonsku mirovinsku dob (65 godina života) i generira sve veći godišnji val transfera prema mirovinskim osiguravajućim društvima. Pritom, portfelji obveznih mirovinskih fondova toliko su narasli da svaki postotak

transfera predstavlja značajan apsolutni iznos. To je dobro za korisnike mirovinskog sustava, ali i za prihode MOD-ova od naknada. Međutim, pod trenutačnim regulatornim okvirom, svaki euro prirasta tehničkih pričuva generira 4,8 eurocenti potrebnog prirasta kapitala. Ubrzanje novčanih priljeva u MOD-ove stoga ne rješava problem njihove ovisnosti o vanjskom kapitalu, već ga povećava na viši apsolutni iznos.

U nastavku se provodi analiza osjetljivosti koja ispituje kako se kapitalne potrebe sektora MOD-a mijenjaju pri različitim stopama organskog rast sektora (tablica 4.). U tu svrhu projicirana su tri scenarija rasta tehničkih pričuva, i to: konzervativni (15% godišnje), bazni (25% godišnje[25]) i optimistični (35% godišnje). Polazište analize je stvarni iznos tehničkih pričuva sektora u 2025. godini od 612,5 mil. EUR. Prihodi od naknada procijenjeni su kao zbroj godišnje naknade (0,17%), obračunate na vrijednost tehničke pričuve iz te godine i jednokratne naknada (1,5%), obračunate na međugodišnji prirast tehničkih pričuva. Operativni troškovi procijenjeni su uz godišnju stopu rasta od 15%[26]. Slobodni novčani tijek MOD-a izračunat je kao razlika neto-dobiti i potrebnog prirasta kapitala, pri čemu je potrebni prirast kapitala (ΔPPK) izračunat prema izrazu (5).

[25] Konzistentno s empirijskim trendom ostvarenim tijekom razdoblja 2022. – 2025.

[26] Prosječni rast operativnih troškova u razdoblju 2020. – 2025. iznosio je 9,5% godišnje, ali njihov nagli rast od 40% u 2025. godini sugerira da sektor ulazi u fazu povećanih operativnih izdataka vezanih uz rast portfelja. Zato se, zbog načela opreznosti, u projekcijama koristi godišnja stopa rasta od 15%.

## Tablica 4. Projekcije rasta tehničkih pričuva hrvatskog sektora MOD-a (mil. EUR), prema različitim scenarijima

| Godina | Tehničke pričuve | Potrebni prirast kapitala | Prihodi od naknada | Operativni troškovi | Neto-dobit | Slobodni novčani tijek | Nužna dokapitalizacija |
|---|---|---|---|---|---|---|---|
| **Scenarij A: Konzervativni rast tehničkih pričuva (15 % godišnje)** | | | | | | | |
| 2026. | 704 | 4,41 | 2,58 | 2,51 | 0,07 | -4,34 | 4,34 |
| 2027. | 810 | 5,07 | 2,96 | 2,88 | 0,08 | -4,99 | 4,99 |
| 2028. | 932 | 5,83 | 3,41 | 3,32 | 0,09 | -5,74 | 5,74 |
| 2029. | 1.071 | 6,71 | 3,92 | 3,82 | 0,10 | -6,60 | 6,60 |
| 2030. | 1.232 | 7,71 | 4,51 | 4,39 | 0,12 | -7,60 | 7,60 |
| **Kumulativno** | - | - | - | - | - | **-29,27** | **29,27** |
| **Scenarij B: Bazni rast tehničkih pričuva (25 % godišnje)** | | | | | | | |
| 2026. | 766 | 7,35 | 3,60 | 2,51 | 1,09 | -6,26 | 6,26 |
| 2027. | 957 | 9,19 | 4,50 | 2,88 | 1,61 | -7,57 | 7,57 |
| 2028. | 1196 | 11,48 | 5,62 | 3,32 | 2,31 | -9,18 | 9,18 |
| 2029. | 1495 | 14,36 | 7,03 | 3,82 | 3,21 | -11,14 | 11,14 |
| 2030. | 1869 | 17,94 | 8,79 | 4,39 | 4,40 | -13,55 | 13,55 |
| **Kumulativno** | - | - | - | - | - | **-47,70** | **47,70** |
| **Scenarij C: Optimistični rast tehničkih pričuva (35 % godišnje)** | | | | | | | |
| 2026. | 827 | 10,29 | 4,62 | 2,51 | 2,11 | -8,178 | 8,18 |
| 2027. | 1.116 | 13,89 | 6,24 | 2,88 | 3,35 | -10,54 | 10,54 |
| 2028. | 1.507 | 18,75 | 8,42 | 3,32 | 5,11 | -13,65 | 13,65 |
| 2029. | 2.034 | 25,32 | 11,37 | 3,82 | 7,56 | -17,76 | 17,76 |
| 2030. | 2.746 | 34,18 | 15,35 | 4,39 | 10,96 | -23,22 | 23,22 |
| **Kumulativno** | - | - | - | - | - | **-73,35** | **73,35** |

Izvor: Izračun autora.

Rezultati analize scenarija otkrivaju nekoliko ključnih zaključaka. Najvažniji jest da kumulativni slobodni novčani tijek MOD-a ostaje negativan u svim scenarijima, u svakoj godini projekcijskog razdoblja i pri svim stopama rasta, čime se potvrđuje hipoteza H2 neovisno o pretpostavci o očekivanom rastu portfelja zbog povećanog priljeva sredstava iz drugog mirovinskog stupa u idućim godinama. Stoga, konstatirana strukturna ovisnost poslovnog modela o priljevu svježeg kapitala, tj. vlasničkoj dokapitalizaciji nije tek artefakt baznih pretpostavki, već inherentno svojstvo regulatornog okvira.

Projekcije upućuju i na svojevrsni paradoks. Naime, dok se kod većine financijskih institucija brži rast poslovanja obično tumači kao pozitivan signal tržišnog uspjeha, kod MOD-a veća stopa rasta tehničkih pričuva – potaknuta zakonski induciranim priljevom osiguranika iz drugog mirovinskog stupa – generira razmjerno veće apsolutne potrebe za dodatnim kapitalom. Razlog tome leži u činjenici što zakonski ograničeni iznosi prihoda od naknada rastu znatno sporije od kapitalnog zahtjeva vezanog uz pričuve[27]. Pri stopi rasta tehničkih pričuva od 35% godišnje kumulativni iznos potrebne dokapitalizacije do 2030. godine procjenjuje se na 73 mil. EUR, nasuprot 29 mil. EUR pri konzervativnom scenariju (godišnja stopa rasta 15%).

Unatoč tome što projekcije u svim scenarijima potvrđuju ostvarivanje neto-dobit, slobodni novčani tijek hrvatskih MOD-ova ostaje negativan, zato što potrebni prirast kapitala ubrzano raste s rastom portfelja korisnika MOD-ova (a time i tehničkih pričuva na kojima se temelji prirast granice solventnosti), te stoga uvijek premašuje iznos neto-dobiti. Ovaj nalaz ukazuje na ključni problem prema kojemu čak i profitabilna institucija može imati negativan slobodni novčani tijek ako regulatorni kapitalni zahtjevi rastu brže od neto-dobiti, što je upravo slučaj kod aktualnih hrvatskih MOD-ova i postojećega regulatornog okvira. Ovime se također potvrđuje hipoteza H2 prema kojoj će sektor i dalje zahtijevati kontinuirane kapitalne injekcije tijekom čitavog projekcijskog razdoblja, neovisno o pretpostavljenoj stopi rasta tehničkih pričuva.

[27] Naknada od 0,17% od tehničkih pričuva nije u stanju kompenzirati prirast potrebnog kapitala u visini od 4,8% prirasta tehničkih pričuva.

# 6. MOGUĆA UNAPRJEĐENJA REGULATORNOG OKVIRA

Na temelju provedene analize vrijedi razmotriti mogućnosti za unapređenje regulatornog okvira. Polazište prijedloga za unaprjeđenje bilo bi da se u projekcijskom modelu (tablica 4.) potrebni prirast kapitala izvodi iz potrebne granice solventnosti, pri čemu se potrebni prirast kapitala (ΔPPK) može aproksimirati umnoškom prirasta tehničkih pričuva sa koeficijentom 0,048 (4,8%). U tom slučaju kapitalni zahtjevi prema MOD-u prije svega bi ovisili o visini tehničkih pričuva, a u manjoj mjeri o stvarnom rizičnom profilu imovine i drugim obilježjima financijskog položaja društva. Prijedlozi koji slijede ukazuju na različite aspekte tog pitanja te se razlikuju prema složenosti i vremenskom horizontu provedbe.

Prvi prijedlog, koji bi se mogao realizirati u kraćem roku, odnosi se na uključivanje slobodnog viška imovine MOD-a u izračun granice solventnosti. Naime, tehničke pričuve MOD-a odgovaraju aktuarskoj sadašnjoj vrijednosti budućih mirovinskih obveza. Kada tržišna vrijednost financijske imovine u aktivi premaši tu aktuarsku vrijednost, nastaje višak imovine koji se, prema postojećem regulatornom okviru, može rasporediti na tri načina. Višak imovine do visine tehničkih pričuva namijenjen je pokrivanju obveza MOD-a prema korisnicima mirovina. Višak imovine iznad toga (101%-110% tehničkih pričuva) ostaje u vlasništvu društva i ne predstavlja ugovornu obvezu prema korisnicima. Višak imovine iznad 110%, a do razine 115% tehničkih pričuva pripisivao bi se korisnicima (umirovljenicima). U ovom slučaju slobodni višak imovine u rasponu 100%-110% tehničke pričuve mogao bi poslužiti kao trajno dostupna rezerva društva koja nije opterećena nikakvim ugovornim obvezama. Kao takva, ta bi se rezerva mogla uključiti u raspoloživu granicu solventnosti MOD-a. Treba napomenuti da čl. 16 st. 2 točka (b) Direktive (EU) 2016/2341 (IORP II) to eksplicitno i predviđa, tvrdeći da raspoloživa granica solventnosti može obuhvaćati slobodne rezerve koje ne odgovaraju preuzetim obvezama prema korisnicima. Presedan u domaćem sektoru MOD-a potvrđuje provedivost ovog mehanizma. Naime, integracija interventnih pričuva jednog društva u 2025. godini — funkcionalno ekvivalentna predloženoj mjeri — materijalno je poboljšala kapitalnu adekvatnost bez ikakve gotovinske injekcije vlasnika. Predložena mjera taj mehanizam eksplicitno ugrađuje u regulatorni okvir i čini ga dostupnim u transparentnim i predvidljivim uvjetima za sva društva. Najveći rizik ovog prijedloga proizlazi iz činjenice da slobodni višak imovine nije jednako stabilan izvor pokrića gubitaka kao vlastiti kapital, budući da

može brzo nestati uslijed nepovoljnih tržišnih kretanja. Time bi se solventnost društva mogla pokazati osjetljivijom na promjene tržišnih uvjeta, nego što je to slučaj u postojećem sustavu.

Drugi prijedlog, koji bi se mogao provesti tijekom dužeg razdoblja, predstavlja prijelaz na kapitalne zahtjeve utemeljene na riziku. Dok prvi prijedlog adresira simptom – nedovoljno prepoznavanje ekonomske snage institucije (MOD-a) unutar zadane formule za izračun potrebne granice solventnosti – ovaj prijedlog fokusira se na uzrok, tj. na neosjetljivost formule na rizični profil ulagačkog portfelja, ili konkretno nerazlikovanje konzervativnog portfelja temeljenog npr. na državnim obveznicama od rizičnijega ulagačkog portfelja (dionice i sl.). Prijelaz na kapitalne zahtjeve utemeljene na riziku, prema metodologiji za izračun zahtijevanog solventnog kapitala (*SCR*[28]), kalibrirao bi kapitalni zahtjev na 99,5% rizične vrijednosti portfelja (*VaR*[29]) kroz jednogodišnji horizont za specifični portfelj MOD-a. Budući da portfelji MOD-ova u pravilu imaju visok udio visokokvalitetnih državnih obveznica niske volatilnosti, iznosi zahtijevanog solventnog kapitala bili bi niži od sadašnje potrebne granice solventnosti. U suradnji regulatora i MOD-ova, takav bi se model mogao uvesti tijekom prijelaznog razdoblja od 3 do 5 godina s paralelnim praćenjem učinaka postojećeg modela izračuna kapitalnih zahtjeva i novog, rizikom utemeljenog modela. Ipak, rizik ovakvog 'dvojnog' pristupa proizlazi iz njegove znatno veće metodološke i operativne složenosti. Za razliku od postojećeg modela, sustav kapitalnih zahtjeva utemeljenih na riziku zahtijevao bi razvoj aktuarskih i stohastičkih modela, dodatne nadzorne kapacitete regulatora, ali i dodatne troškove implementacije, kako za regulatora, tako i za same MOD-ove.

Osim izravnog financijskog učinka, predložene reformske mjere adresiraju i širi javni interes. Sama struktura postojećega regulatornog okvira implicira teorijski poticaj prema kojemu bi vlasnik MOD-a, koji optimizira kapitalne tijekove, mogao imati opravdanje za usporavanje rasta portfelja, obzirom da svaki euro novog portfelja zahtijeva dodatnih 4,8 eurocenti novog kapitala koji organska dobit ne može apsorbirati. Ovako definirana struktura je, teorijski gledano, u suprotnosti s javnim interesom za maksimalnim preuzimanjem novih korisnika iz drugog mirovinskog stupa u MOD-ove.

[28] *Solvency Capital Requirement* predstavlja središnji kapitalni zahtjev u okviru *Solvency II* (Direktiva 2009/138/EZ) za osiguravajuća društva u EU, a koji se konceptualno znatno razlikuje od načina utvrđivanja potrebne granice solventnosti koju propisuje hrvatski ZMOD.

[29] *Value at Risk*.

Reformirani okvir, koji priznaje slobodni višak imovine i/ili uvodi rizikom utemeljene kapitalne zahtjeve, ublažio bi tu neusklađenost i bolje približio interese vlasnika s javnim interesom mirovinskog sustava.

# 7. ZAKLJUČAK

Rezultati istraživanja potvrđuju obje istraživačke hipoteze. Kumulativni slobodni novčani tijek hrvatskog sektora mirovinskih osiguravajućih društava u razdoblju 2021. – 2025. iznosi -21,1 mil. EUR, uz impliciranu dokapitalizaciju od 32,8 mil. EUR (18,9 mil. EUR nakon korekcije za negotovinsku komponentu), što je u skladu s H1. Dokazuje se da rast tehničkih pričuva MOD-ova sustavno generira kapitalne zahtjeve koje interna dobit sektora ne uspijeva pokriti, budući da prirast potrebnog kapitala od 4,8% za svaki euro novih pričuva strukturno premašuje prihode od naknade za upravljanje. Inflacijska epizoda iz 2022. godine, kada je kombinacija zakonskih usklađenja mirovina i pada vrijednosti portfelja iziskivala dokapitalizaciju sektora MOD-a od oko 19 mil. EUR unutar jedne godine pokazuje da inflacijski rizik u sektoru MOD-a djeluje primarno kao sistemski, a ne kao idiosinkratski rizik specifičan za pojedino društvo. Projekcije od 2026. do 2030. godine u skladu su s H2, jer niti ubrzani priljev korisnika iz drugog mirovinskog stupa u sektor mirovinskih osiguravajućih društava neće ukloniti potrebu za kontinuiranim kapitalnim injekcijama vlasnika, već je, zbog pozitivne koreliranosti rasta sektora i kapitalnih potreba, dodatno povećava. Šire implikacije rada upućuju na zaključak da je poslovni model isplata mirovina putem MOD-ova dizajniran više kao javna usluga nego kao profitabilna financijska djelatnost, na što upućuje i strukturno negativan slobodni novčani tijek hrvatskih MOD-ova u analiziranom razdoblju. Regulatorni okvir koji na taj način „penalizira“ rast financijskog portfelja potencijalno nosi rizik stvaranja neusklađenih poticaja za usporavanje poslovnog rasta. Na temelju ovih nalaza, predlažu se dvije međusobno kompatibilne regulatorne mjere, i to: kratkoročno uključivanje slobodnog viška imovine (100-110% tehničkih pričuva) u raspoloživu granicu solventnosti društava, a u skladu s direktivom *IORP II*, te dugoročni prijelaz na kapitalne zahtjeve utemeljene na riziku, po uzoru na direktivu *Solvency II*, čime bi se kapitalni zahtjevi uskladili sa stvarnim rizičnim profilom portfelja. Ipak, rezultate treba tumačiti uz određena ograničenja – analiza se temelji na agregatnim podacima dvaju hrvatskih MOD-ova i ne uključuje mikroanalizu pojedinačnih ugovora niti detaljno modeliranje dugovječnosti umirovljenika,

dok projekcije do 2030. godine, koje predstavljaju scenariji, a ne predviđanja, primarno ovise o pretpostavkama o rastu tehničkih pričuva, inflaciji i troškovima.

# LITERATURA

Antolín, P. (2008), Pension Fund Performance, *OECD Working Papers on Insurance and Private Pensions*, No. 20, OECD Publishing, Paris, https://doi.org/10.1787/240401404057.

Antolín, P., Stewart, F. (2009), Private Pensions and Policy Responses to the Financial and Economic Crisis, *OECD Working Papers on Insurance and Private Pensions*, No. 36, OECD Publishing, Paris, https://doi.org/10.1787/224386871887.

Barr, N., Diamond, P. (2008). *Reforming Pensions: Principles and Policy Choices*. Oxford: Oxford University Press.

Bejaković, P. (2019). Uzroci poteškoća u mirovinskom sustavu i razlozi zašto treba očuvati kapitalizirano mirovinsko osiguranje u Hrvatskoj, *Revija za socijalnu politiku*, 26(1), str. 37-52.

Bežovan, G. (2019). Evaluacija procesa privatizacije mirovinskog sustava u Hrvatskoj, *Revija za socijalnu politiku*, 26(1), str. 1-35.

Blake, D. (2006). *Pension Finance*. Chichester: Wiley Finance.

Damodaran, A. (2012). *Investment Valuation: Tools and Techniques for Determining the Value of Any Asset* (3. izdanje). Hoboken: Wiley Finance.

Damodaran, A. (2022). *The Dark Side of Valuation* (3. izdanje). Hoboken: Pearson.

Direktiva (EU) 2016/2341 Europskog parlamenta i Vijeća od 14. prosinca 2016. o djelatnostima i nadzoru institucija za strukovne mirovine *(IORP II)*.

Direktiva 2009/138/ EZ Europskog parlamenta i Vijeća od 25. studenog 2009. o pokretanju i obavljanju djelatnosti osiguranja i reosiguranja *(Solvency II)*.

DZS (2026). Indeks potrošačkih cijena 2019. – 2025. Zagreb: Državni zavod za statistiku. www.dzs.hr.

HANFA (Hrvatska agencija za nadzor financijskih usluga), *Financijska stabilnost*, godišnja publikacija (2021., 2022., 2023.), www.hanfa.hr.

HANFA (2019. – 2025.). Godišnja izvješća o stanju na financijskim tržištima. Zagreb: Hrvatska agencija za nadzor financijskih usluga.

HANFA (Hrvatska agencija za nadzor financijskih usluga). Regulativa — Mirovinski sustav. Zagreb: HANFA. https://www.hanfa.hr/regulativa/mirovinski-sustav/ (pristupljeno: 6.9.2026.).

Hrvatski zavod za mirovinsko osiguranje. (2026). *Statističke informacije Hrvatskog zavoda za mirovinsko osiguranje, godina XXIV., broj 5/2026. (lipanj 2026.).*

Hrvatsko mirovinsko osiguravajuće društvo (2020. – 2025.). Godišnji financijski izvještaji. Zagreb: HRMOD.

Impavido, G., Rocha, R.(2006). Competition and performance in the Hungarian second pillar. *Policy Research Working Paper Series* 3876, The World Bank.

Koller, T., Goedhart, M., Wessels, D. (2010). *Valuation: Measuring and Managing the Value of Companies* (5. izdanje). Hoboken: McKinsey & Company / Wiley Finance.

Merton, R. C. (1974). On the Pricing of Corporate Debt: The Risk Structure of Interest Rates. *Journal of Finance*, 29(2), 449–470.

Nestić, D., Potočnjak, Ž., Puljiz, V., Rašić Barakrić, I., Švaljek, S., Tomić, I., Vehovec, M., Vukorepa, I. (2011). Izazovi i mogućnosti za ostvarenje primjerenih starosnih mirovina u Hrvatskoj, Projektna studija, Ekonomski institut Zagreb.

Pennacchi, G., Rastad, M. (2011). Portfolio Allocation for Public Pension Funds. *Journal of Pension Economics and Finance*, 10(2), 221–245.

Pravilnik o strukturi i sadržaju financijskih i dodatnih izvještaja MOD-a (NN 152/24, s izmjenama NN 155/25).

Pravilnik o vrednovanju imovine MOD-a (NN 152/24).

Pravilnik o kontnom planu MOD-a (NN 30/23).

Pravilnik o interventnim pričuvama MOD-a (NN 117/25).

Pravilnik o adekvatnosti kapitala mirovinskog osiguravajućeg društva (NN 74/14, 121/16, 116/19).

Pravilnik o minimalnim standardima obračuna tehničkih pričuva (NN 20/24).

Raiffeisen mirovinsko osiguravajuće društvo d.d. (2019. – 2025.). Godišnji financijski izvještaji. Zagreb: RMOD. Dostupno na: www.rmod.hr/godisnja-financijska-izvjesca/1589

Samodol A. (2020). Mirovinske reforme kao trajno globalno pitanje i dizajniranje mirovinskog sustava – slučaj Hrvatske, Međunarodne studije, 20(1-2), str. 79-95.

Severinson, C., Yermo, J. (2012). The Effect of Solvency Regulations and Accounting Standards on Long-Term Investing. *OECD Working Papers on Finance, Insurance and Private Pensions*, br. 30. Paris: OECD.

Stigler, G. J. (1971). The Theory of Economic Regulation. *Bell Journal of Economics*, 2(1), 3–21.

Vukorepa, I. (2015). Lost between Sustainability and Adequacy: Critical Analysis of the Croatian Pension System's Parametric Reform**.** *Revija za socijalnu politiku*, 22(3), 279–308. https://doi.org/10.3935/rsp.v22i3.1307

Whitehouse,E. (2009). Pensions, Purchasing-Power Risk, Inflation and Indexation, *OECD Social, Employment and Migration Working Papers*, br. 7, OECD Publishing, Paris, https://doi.org/10.1787/227182142567.

Zakon o izmjenama i dopunama Zakona o mirovinskim osiguravajućim društvima (NN 52/25).

Zakon o mirovinskim osiguravajućim društvima, (NN 22/14, 29/18, 115/18, 156/23, 52/25 i 13/26).

*Ovaj je rad financiran u okviru projekta Suvremeni izazovi održivosti u kontekstu globalnih promjena (CHASING), iz izvora 581 – Mehanizam za oporavak i otpornost.*

# STRUCTURAL SUSTAINABILITY OF THE BUSINESS MODEL OF PENSION INSURANCE COMPANIES IN THE REPUBLIC OF CROATIA

***Abstract***

*Pension insurance companies (PICs) represent an important institutional component of the reformed pension system in the Republic of Croatia, as they enable the conversion of accumulated savings from the mandatory pension funds into lifelong pension benefits. Despite their importance and the strong growth of the sector, the financial sustainability of the PIC business model remains insufficiently explored in Croatian literature. This paper analyses the sustainability of the PIC business model by using aggregate data of the sector for the period 2020–2025, and the projections of capital requirements for the period 2026-2030. The aim is to assess the extent to which the existing regulatory framework enables companies to finance the growth of capital requirements, associated with increasing technical provisions and assumed pension liabilities, from internally generated earnings. The analysis is based on financial statements of the two Croatian PICs and on Damodaran's approach to the valuation of regulated financial institutions, adapted to the specific characteristics of the sector. Free Cash Flow to Equity (FCFE) is used as an indicator of capital self-sustainability, whereby an increase in regulatory capital requirement is seen as the functional equivalent of capital expenditures necessary for the continuation of business operations. In the historical analysis, FCFE is calculated by using the actual increase in the required solvency margin (RSM), while the projection model applies the required capital increase (RCI), defined as the capital necessary to maintain the capital position at 120% of the RSM, or approximately 4.8% of the increase in technical provisions (TP). The paper test two research hypotheses. According to the first hypothesis (H1), based on historical data for the period 2020-2025, the increase in technical provisions of PICs constantly generates capital requirements which the sector cannot finance through internally generated profit. According to the second hypothesis (H2), and projections of capital requirements for the period 2026-2030, even the increased inflow of pensioners from the second pension pillar into the PIC sector would not eliminate the need for further capital injections of the owners. Empirical results for the period 2020-2025 show very limited capacity of the PIC sector for financing the growing capital requirements, while projections by 2030 suggest the need for further increase in technical*

*provisions in all the scenarios. Hence, results support the idea of limited organic self-sustainability of the existing business model of Croatian PICs, hence providing the ground for possible regulatory adjustments. These include the broader definition of the available capital reserves, and, a long-term transition towards capital requirements based on the actual risk profile of the portfolio.*

***Keywords:*** *pension insurance companies, solvency, capital adequacy, technical provisions, free cash flow to equity.*

JEL klasifikacija: E31, E42, E52, F45

Prethodno priopćenje

# EURO U REPUBLICI HRVATSKOJ I PERCEPCIJA NJEGOVIH UČINAKA MEĐU GRAĐANIMA[1]

Dora Hercezi*

Željko Bogdan**

## SAŽETAK

Republika Hrvatska uvela je euro 1. siječnja 2023. godine i time postala članica eurozone. Cilj rada bio je objasniti razloge uvođenja eura kroz više argumenata u prilog i protiv toga s naglaskom na njegove učinke na cijene i kupovnu moć te ispitati percepciju građana o toj promjeni. U objašnjavanju učinaka na cijene i kupovnu moć korišteni su statistički podaci o kretanju inflacije, plaća i realne kupovne moći. Rezultati pokazuju da je najjači rast cijena bio u razdoblju globalnih poremećaja, osobito tijekom 2022. godine, prije samog uvođenja eura. Nakon konverzije inflacija se postupno smanjivala, dok su plaće rasle brže nego u prethodnim godinama, što je pridonijelo oporavku kupovne moći građana. Na temelju prikazanih podataka

* Dora Hercezi, bacc. oec. (e-mail: dorahercezi@gmail.com).

** Prof. dr. sc. Željko Bogdan, Sveučilište u Zagrebu, Ekonomski fakultet (e-mail: zbogdan@efzg.hr), korespondirajući autor.

[1] Istraživanje za ovaj članak u empirijskom dijelu rada proizašlo je iz završnog rada Hercezi (2026) čiji je mentor bio Željko Bogdan koji ovaj tekst posvećuje pokojnom srednjoškolskom profesoru i nastavničkom uzoru Šimi Uremu od kojeg je stekao svoja prva znanja iz monetarne politike, monetarne povijesti i statistike. Za školski list Sedmi sat Ekonomske, upravno-birotehničke i trgovačke škole u Šibeniku (danas Ekonomska škola) je prof. Urem objavljivao tekstove iz novčarstva. Iako su sveučilišni nastavnici unaprijedili naše znanje, ne smijemo zaboraviti ni srednjoškolske nastavnike koji su nam usadili „abecedu struke“ i opća znanja.

može se zaključiti da euro nije bio glavni uzrok inflacije, nego je uveden u razdoblju već postojećih cjenovnih pritisaka. Empirijski dio rada temelji se na anketnom istraživanju provedenom na uzorku od 158 ispitanika. Rezultati ankete pokazali su da velik broj građana povezuje euro s rastom cijena, osobito kod hrane, goriva i usluga. Većina ispitanika smatra da plaće nisu dovoljno pratile troškove života, ali istodobno prepoznaje i određene prednosti eura, poput stabilnije valute, lakših putovanja i jednostavnijeg plaćanja u inozemstvu. Rad pokazuje da postoji razlika između službenih ekonomskih pokazatelja i subjektivnog doživljaja građana.

**Ključne riječi:** euro, Hrvatska, inflacija, kupovna moć, percepcija učinaka eura.

## 1. UVODNA RAZMATRANJA I MALO MONETARNE POVIJESTI HRVATSKE

U XX. stoljeću na prostoru današnje Hrvatske mijenjaju se različita sredstva plaćanja: austrougarska kruna/forint, jugoslavenski dinar (obje države), kuna Nezavisne Države Hrvatske (NDH) i naposljetku hrvatski dinar (CRD/HRD[2]) koji i nije bio novac u punom smislu te riječi jer ga je izdavalo Ministarstvo financija, a ne središnja banka. Uvođenjem HRD-a započeo je proces monetarnog osamostaljenja Hrvatske koji je krunu imao u vlastitoj valuti – hrvatskoj kuni (HRK) koja je zaživjela s Danom državnosti 1994. godine. Iako njezin naziv podsjeća na prethodnicu iz Drugoga svjetskog rata, kuna ima podlogu u hrvatskoj monetarnoj povijesti. Tako je kunovina u dijelovima današnje Hrvatske tijekom srednjeg vijeka služila kao novac. Motiv kune u trku prepoznatljiv je bio na našim kovanicama kune i ostat će sačuvan i na hrvatskim eurima. Ali je on postojao i ranije na slavonskom banovcu koji je bio prepoznat i izvan granica Hrvatske (samo što je u ranim počecima dok se banovac kovao u Pakracu bio karakterističan trk kune ulijevo da bi kasnije vjerojatno sa preseljenjem kovnice u Zagreb ona trčala udesno)[3]. Imidž

[2] Prvotna kratica za hrvatski dinar je bila CRD, ali je 2. travnja 1992. promijenjena u HRD.

[3] O banovcu, ali i dubrovačkom novcu više se može naći u Milinović (2002) ili u Kolar-Dimitrijević (2013). Posebno je zanimljiva teza da je vrlo „znakovito da je Hrvatski državni sabor 1731. dao potporu već dobro prihvaćenoj uporabi dubrovačkoga srebrnog novca pod nazivom »hrvatski denar« (*denarius croaticus*) u sjevernoj Hrvatskoj, unatoč zabrani cara Karla VI.“ (Milinović, 2002). Zanimljiva je koincidencija s nazivom hrvatski dinar iz 1990-ih godina. Banovce je 1364. godine zabranio kovati kralj Ludovik Anžuvinac (1342. – 1382.) jer je bio skloniji kraljevskom novcu iako je vjerojatno da se banovac u zagrebačkoj kovnici novca potajno kovao neko vrijeme, sve do početka

banovca u povijesti te lik kune u trku – kuna između dvije rijeke je i dio grba Slavonije – zajednička je inspiracija za ime i valute NDH i valute suvremene Hrvatske. Nakon skoro 30 godina u optjecaju kuna je 1. siječnja 2023. godine prestala biti zakonsko sredstvo plaćanja. Ali kovanice s kunom u trku cirkulirat će diljem Europe kao što je to bilo nekada s banovcem.

Zajedničko svim valutama koje su kuni tijekom XX. stoljeća neposredno prethodile jest da su sve nestale s prestankom postojanja država koje su simbolizirale. Ali sada smo dobrovoljno odlučili napustiti vlastitu valutu i prijeći na euro. Mnogi na ovo gledaju kao na obvezu preuzetu Ugovorom o pristupanju o Europskoj uniji (što je točno) iako on nije predviđao dinamiku uvođenja eura; odluka o tome bila je na izvršnim i monetarnim vlastima zemlje. Zadovoljni tom odlukom njezine koristi vide u izostanku mijenjanja valuta, lakšim uspoređivanjima cijena i putovanjima te olakotnim okolnostima za naš turizam. Drugi će gledati gubitak monetarnog suvereniteta (pa i nacionalnog zbog čvršćeg integriranja). Ankete iz srpnja 2022. godine sugerirale su da je 52% građana Hrvatske za euro, a 40% za zadržavanje kune[4]. Relativno visok udio onih koji nisu biti zagovaratelji eura svakako je bio povezan sa strahom od rasta cijena, ali tezom o gubitku monetarnog suvereniteta pa je objasniti njihove argumentacije prvi cilj ovog rada. Usporedo s tim, nezaobilazno je i komentiranje tečajnog rizika i optimalnoga valutnog područja. Drugi cilj je prikazati iskustva građana s novom valutom na temelju ankete. Na taj se način želi pokazati koliko objektivni ekonomski pokazatelji prate i subjektivni doživljaj građana.

U skladu s navedenim struktura rada je sljedeća: u drugoj sekciji prikazuju se najvažniji argumenti u prilog i protiv eura u Hrvatskoj; u trećoj sekciji se istražuju iskustva građana s novom valutom a u četvrtoj i posljednjoj zaključuju naša razmatranja.

XV. st. (Kolar-Dimitrijević, 2013). Datirani spomen kovanja banovca u Pakracu smješta se u 1256. godinu (moguće je da je postojao i ranije), ali se od 1260. do 1384. godine kuje u Zagrebu.

[4] Tvrdnja se može naći na stranici Eurobarometra (European Commission, 2022). Drugo je pitanje koliko su te ankete pristrane jer je dio ljudi u proteklom razdoblju navikao na domaću valutu, a mnogi su bili u strahu od rasta cijena. Stvaran stav građana o kuni pokazao bi referendum, ali nije bio održan, što se službeno objašnjavalo obvezom zbog pristupa u EU. Za razliku od Hrvatske u Švedskoj je, primjerice, dvaput održan referendum kojim se odbilo prijeći na novu valutu dok Danska jedina u EU ima opt-out klauzulu prema kojoj nije obvezna uvesti euro.

# 2. ARGUMENTI HRVATSKE ZA UVOĐENJE EURA

Opisivanje monetarne povijesti Europske unije (EU) koja je dovela do stvaranja Europskog monetarnog sustava (EMS) i Europske monetarne unije (EMU) značajno bi povećala i onako velike gabarite ovog rada[5]. Umjesto toga, prezentirat će se nekoliko osnovnih argumenata u prilog i protiv samog eura. U korist euru svakako idu eliminacija tečajnog rizika, olakšavanje vanjske trgovine te sukreiranje monetarne politike. A protiv toga su strah od rasta cijena te gubitak monetarnog suvereniteta.

## Euro i cijene

S prestankom pandemijske krize došlo je do oživljavanja inflacije koja je zadnjih godina jedna od vodećih ekonomskih tema u Hrvatskoj[6]. Stoga je na slikama 20. i 21. u Dodatku prikazano kretanje prosječne godišnje stope inflacije (mjereno stopom promjene harmoniziranog indeksa potrošačkih cijena – HICP) raščlanjeno prema najvažnijim doprinosima. Najveće su stope inflacije zabilježene tijekom 2022. (10,7%) i 2023. godine (8,4%), ali i nakon toga ne spušta se ispod 4%, što je čini jednom od najvećih inflacija u eurozoni[7]. Značajno su inflaciji u tom vremenu pridonosile cijene hrane, troškovi stanovanja, pa čak i cijene u restoranima te usluga smještaja[8].

Uvođenje eura u uvjetima najveće inflacije opravdano nameće pitanje koliko je ono pridonijelo inflaciji kada je strah od toga uvijek postojao. Uzme li se u obzir zaokruživanje cijena zbog prijelaza na novu valutu koje bi negdje bio

[5] Sažeti prikaz monetarne povijesti Europe nakon Drugoga svjetskog rata dan je, primjerice, u Blanchard, Amighini i Giavazzi (2010) i Deskar-Škrbić i Kunovac (2019). Proces koji je morala proći Hrvatska u procesu pristupa eurozoni opisan je i u Mijatović i Bogdan (2022) i tamo dostupnoj literaturi.

[6] U skladu s tim ona je u više navrata bila i tema na savjetovanjima ekonomista u Opatiji. Vidjeti npr. radove: Bogdan (2021, 2022a), Rogić Dumančić, Raguž Krištić i Rogić Kovač (2022). Zanimljive analize inflatornih kretanja mogu se naći i u: Ivanac, Kunovac i Nadoveza (2024), Mužić i Žilić (2024), Nadoveza (2025), Tkalec i Žilić (2025, 2026) i drugim istraživanjima.

[7] Briga o potrošačkoj inflaciji također proizlazi i zbog utjecaja na kupovnu moć. Ali na nju utječe i visina plaće i mirovina. U dodatku je također prezentirana i dinamika nominalne i realne plaće u Hrvatskoj između 2017. i 2026. godine (slika 21.). Prosječna nominalna plaća 2026. je za 83% veća u odnosu na predpandemijsku 2019. godine. S druge strane, povećanje prosječne realne plaće u istom razdoblju znatno je manje (34%) (snažniji rast cijena u odnosu na nominalne plaće). Uslijed snažne inflacije tijekom 2022. godine je realna plaća bilježila smanjenje.

[8] Utjecaj cijena u restoranima i uslugama smještaja vezan je uz ovisnost Hrvatske o turizmu posebno u primorskom kraju. Veza turizma i cijena u Hrvatskoj je istražena u Kožić, Sorić i Sever (2024) i Tkalec i Žilić (2026).

naviše, a negdje naniže određen porast razine cijena je bio izgledan, moguće za oko 0,4 – 0,6%, što je minimalan porast. Zato se neposredno nakon uvođenja eura pratilo cijene i primjetna su bila poskupljenja pojedinih namirnica već u prvim danima 2023. godine. Vlada je potom posegnula za mjerama kojima se poticalo trgovce da vrate cijene na 31. prosinca 2022. godine. Prema podacima DZS-a cijene u siječnju 2023. su u prosjeku zaista bile jednake onima u prosincu 2022. godine, što je trebalo uvjeriti da je strah od značajnog rasta cijena ipak bio neopravdan. I u preliminarnoj analizi autora Europske središnje banke (ESB) i Hrvatske narodne banke (HNB) utjecaj uvođenja eura na rast cijena u Hrvatskoj u siječnju i veljači 2023. godine iznosio je 0.4 postotna boda (Falagiarda, Gartner, Mužić i Pufnik, 2023). Ni u Sorić (2024) nije potvrđen značajan utjecaj eura na agregatnu razinu cijena, no na razini proizvoda i usluga bio je zamijećen u cijenama hrane, odjeće i cijena u restoranima.

Ali zato je moguće da upravo cijene hrane igraju odlučujući utjecaj na percepciju građana o učinku eura. Vratimo li se na službenu statistiku iz veljače 2023. godine, u „prosjeku iste cijene" ne znače da se cijene uopće nisu mijenjale, već da su neki artikli poskupjeli, a drugi pojeftinili, tako da je razina cijena ostala ista. Tako su npr. cijene hrane u siječnju 2023. godine bile u prosjeku veće za 1,5% u odnosu na prosinac 2022. godine. To ne izgleda osobito snažnim, ali je na godišnjoj razini to rast od 19,56%[9], te da je za najsiromašnije kategorije ljudi koji u Hrvatskoj zauzimaju značajan udio najvažniji udio izdataka za hranu te je i ovakav rast za njih izrazito velik[10].

No izrečeno otvara pitanje *izbora tajminga pristupanja eurozoni*. Uoči prelaska na euro bili smo zabrinuti bi li, možda, rastuća inflacija mogla ugroziti pristup Hrvatske eurozoni. Danas se u ispravnost pristupa pravdamo

[9] Uz rast od 1,5% mjesečno razina idućih 12 mjeseci cijene hrane u siječnju 2024. godine bile bi u prosjeku veće za $1.015^{12} - 1 = 19{,}56\%$ u odnosu na siječanj 2023. godine.

[10] Pred samu pandemiju cijene hrane bile su najvažniji pojedinačni uzročnik inflacije. Tijekom 2020. i 2021. godine najsnažniji utjecaj na inflaciju imale su cijene goriva i maziva. Pozitivan doprinos cijena hrane se tijekom 2020. godine smanjivao i postajao negativan. Od ljeta 2021. godine on je ponovno pozitivan i rastući te od prosinca 2021. do danas najsnažnije pridonosi inflaciji u Hrvatskoj. Često se rast cijena hrane pripisuje bahatosti prehrambene industrije, ali takav stav ne opravdava analiza Vizek (2023). No godišnji rast cijena hrane je u Hrvatskoj ipak bio slabiji nego u većini zemalja srednje i istočne Europe jer se pokazalo da je inflacija cijena hrane jače porasla u zemljama koje u znatnijoj mjeri uvoze poljoprivredne proizvode iz Ukrajine, Rusije i Bjelorusije (HNB, 2022). Dodatno, Kunovac, Batušić i Čorak (2026) ističu da su vanjski poremećaji na strani ponude bili glavni začetnik inflacije hrane u Hrvatskoj i ostatku europodručja, ali da Hrvatsku izdvaja „brzina i lakoća kojima su trgovci te troškove prenosili na potrošače" te ističu da eskalacija sukoba na Bliskom istoku stvara rizike novog inflacijskog vala.

tezom da je utjecaj eura na agregatnu razinu cijena minimalan. Čak je inflacija nešto ništa na razini eurozone nego na razini EU-27, što znači da je veća u zemljama s vlastitom valutom. Činjenica jest da je od 2021. do 2023. inflacija bila veća u članicama EU izvan eurozone i da je u deset zemalja s najnižom inflacijom u EU samo jedna ili dvije nisu imale euro. No i u deset zemalja s najvećim stopama inflacije također ih je pet ili šest koristilo euro kao službenu valutu. Već ta činjenica pokazuje da su, kada je inflacija u pitanju, različitosti među zemljama očite i sigurno se ne mogu nužno pripisati uvođenju eura ili zadržavanju vlastite valute[11].

## Pitanje monetarnog suvereniteta

Kada se sudi o ispravnosti odluke o preuzimanju eura, često se postavlja i pitanje monetarnog suvereniteta. Iako ga mnogi svode na simboliku i na vlastito sredstvo plaćanja, u to se uključuje i samostalno vođenje monetarne politike. Iz osnova makroekonomije znano je da njezini učinci tijekom vremena iščezavaju, ali da je koristan alat za ispravljanje poslovnih ciklusa premda se to isuviše pojednostavnjuje. To znači da se u recesijskim uvjetima, zbog veće nezaposlenosti, više valja fokusirati na kratkoročne ciljeve, što ekspanzivnu monetarnu politiku čini poželjnom. Jasno, to se – naročito u malim otvorenim gospodarstvima – ne može promatrati odvojeno od tečaja. Ekspanzivna monetarna politika sa sobom povlači i nominalnu deprecijaciju domaće valute. No porast izvoza (i smanjenje uvoza) vezuje se uz realnu deprecijaciju. Kolika će se realna deprecijacija dogoditi zbog nominalne deprecijacije ovisi o utjecaju tečaja na cijene, što je osobito važno za mala otvorena gospodarstva. Naime, u njima je dio dobara koje koriste domaći rezidenti uvoznog porijekla pa će s deprecijacijom i njihove cijene porasti, a time i opća razina cijena. S prilagodbom cijena početna realna deprecijacija bit će ublažena, što za sobom pritišće i novu promjenu tečaja i novi rast cijena pa ni realna aprecijacija nije isključena.

No učinkovitost spomenute monetarne ekspanzije vezana je uz potražnju za kreditima (koja je manja u recesijskim uvjetima), ali u udžbenicima se zanemaruje i utjecaj neslužbene euroizacije / dolarizacije. Financijska statistika Hrvatske je u rujnu 2022. godine pokazivala da je udio deviznih

[11] Tako su npr. Švedska i Danska zadržale vlastitu valutu, a inflacija u Švedskoj je bila 2,7% (2021.), 8,1% (2022.) i 5,9% (2023.). Danska je imala inflaciju od 1,9% (2021.), 8,5% (2022.) i 3,4% (2023.) i uvijek je u promatranom vremenu u skupini deset zemalja s najnižom stopom inflacije.

depozita u ukupnim štednim i oročenim depozitima 88,88%, većinom u eurima! Naravno, bilo je više uzročnika ovakve euroizacije, ali im je zajednički nazivnik negativno iskustvo s inflacijom u prošlosti[12]. 1980-e te prva faza Domovinskog rata (do 1993. godine) doba su snažne godišnje inflacije u Hrvatskoj koja je ponekad godišnje značajno premašivala i 1000%. Ali su iskustvo s inflacijom imale i druge (post)socijalističke zemlje pa stupanj euroizacije nije bio ni blizu hrvatskog. Dakle, sigurno su postojali i drugi Hrvatskoj specifični uzročnici poput radničkih doznaka iz inozemstva, ovisnosti o turizmu, udjela stranih banaka u aktivi našeg bankarskog sustava, očekivanja uvođenja eura u budućnosti, ali i često potenciranje tečajne politike HNB-a. Naime, isticanje prejake kune podrazumijeva da će ona kad-tad u budućnosti deprecirati, što znači i zaradu za štediše u inozemnoj valuti[13]. Snažna euroizacija pokazuje da kuna funkciju *sredstva pričuve vrijednosti* gotovo da nije vršila. Dobro je obavljala funkciju *sredstva plaćanja,* dok je funkciju *mjere vrijednosti* obavljala polovično jer su se skuplje vrijednosti (stanovi, automobili) iskazivali u većinom u eurima.

Depoziti su izvori sredstava za banku iz kojih ona odobrava kredite. I kada su oni u eurima, teoretski možemo zamisliti da se odobravaju samo kunski krediti. Slabljenje kune tada ne bi utjecalo na kreditne rate dužnika, ali bi rasli rashodi banaka prema štedišama. Ako bi dominirali i krediti u eurima, i dalje bi deprecijacija kune povećala rashode prema štedišama, ali bi se povećavale i kreditne rate dužnicima koji imaju primanja u domaćoj valuti. U prvom slučaju je prisutan tečajni rizik, dok je u drugom on prevaljen na korisnike kredita, ali sa snažnijom deprecijacijom kune raste udio onih koji neće moći vraćati kredit (rast kreditnog rizika). Obje ove situacije odražavaju se u visini kamatne stope, ali utjecaj imaju i strože regulative uslijed euroizacije koje potiču veću kapitaliziranost banaka i također reflektiraju u većim kamatnim stopama. Ipak, više kapitala bankama omogućuje da prevladavaju nepovoljne uvjete (slabljenje domaće valute, recesiju) i da se očuva povjerenje u domaći bankovni sustav. Zato se nekada kao glavni argument za uvođenje eura isticalo smanjenje kamatnih stopa osobito ako je veći dio rizika povezan sa tečajem. Recentna situacija je da se cijela eurozona borila s rekordno visokom inflacijom protiv koje su nužne veće kamatne stope, pa se više bilo počelo

[12] Vidjeti primjerice: Ivanov, Tkalec i Vizek (2011), Tkalec (2012), Tkalec i Verbič (2013) i Faulend (2014).

[13] Vidjeti npr. Martinis (2020) i Nadoveza Jelić i Ravnik (2022).

isticati da će kamatne stope biti manje u odnosu na slučaj da smo zadržali vlastitu valutu.

Stvarni podaci prije 2023. godine bili su signalizirali dominantan udio kredita u eurima iako se tijekom vremena smanjivao. On je 2002. godine (kada je euro zaživio u većini EU-15 zemalja) u Hrvatskoj premašivao 3⁄4 svih kredita, dok udio kunskih kredita nije bio veći od petine. Tijekom vremena udio kunskih kredita povećavao se pa je potkraj 2021. godine njihov udio (49,9%) bio čak blago veći od eurskih (49,2%). Kunizacija hrvatskoga bankarskog sustava na strani kredita ipak nije eliminirala rizike u bankovnom sustavu[14]. To se osobito vidi prema udjelu kredita u švicarskim francima koji ni za najveće popularnosti (2007. i 2008. godine) nije premašivao više od 18% svih kredita. Aprecijacija švicarskog franka zadnjih 15-ak godina i ekspanzivne mjere HNB-a sigurno su pridonosili rastu udjela kunskih kredita. Tijekom 2022. godine udio kunskih kredita se smanjuje čemu su sigurno pridonijele i najave o uvođenju eura 1.1.2023. godine.

Euroizacija bi sigurno utjecala na učinkovitost ekspanzivne monetarne politike i u recesiji. Pri slobodnom kretanju kapitala bilo je izgledno slabljenje kune koje možda potakne izvoz jer u njegovoj strukturi sa otprilike 60% dominiraju proizvodi niske i srednje niske tehnološke razine. Njima bi deprecijacija kune mogla potaknuti cjenovnu konkurentnost naročito ako uvozna ovisnost nije snažna. Uvoz bi vjerojatno poskupio, ali je pitanje koliko bi opala njegova razina (mala smo ekonomija pa bez dijela uvoznih proizvoda ne možemo!). Zbog euroizacije bi, ipak, bila pogoršana kreditna zaduženost značajnog dijela klijenata[15]. Tako bi osnovni alat protiv recesije mogao djelovati kontraproduktivno odnosno prorecesivno. Uz slobodno kretanje kapitala, neovisna ekspanzivna monetarna politika za sobom povlači neželjen scenarij (rast rata kredita zbog deprecijacije kune). Nezavisna monetarna politika podrazumijevala bi ili odricanje od slobodnog kretanja kapitala (što nismo smjeli nakon ulaska u EU) ili odricanje od stabilnog tečaja (jako skupo zbog euroizacije). Jednostavno smo bili u situaciji gdje nam je monetarni suverenitet već i uz vlastitu valutu značajno bio sužen.

Slab manevarski prostor HNB-u nije značio da se deprecijacijom tečaja (naročito kada su domaća i inozemna inflacija bile blizu nule) moralo poticati izvoz uz velike troškove domaćim sektorima. Recesijska kretanja obično

[14] Kako se banke bore s tečajnim rizikom opisano je u HUB (2014).

[15] Vidjeti npr. spomenuti članak Tkalec i Verbič (2013).

prati pad domaće potražnje (koja uključuje i uvozna dobra) koji pridonosi i deprecijaciji domaće valute koja se tako nameće kao faktor koji ublažava recesiju. Slaba deprecijacija može poticati izvoz bez značajnog pogoršanja zaduženosti sektora koji su euroizirani. Naravno, do nje dolazi automatski kroz prorijeđene intervencije središnje banke na deviznom tržištu (Buchen i Wollmershäuser, 2016). S prelaskom na euro realna deprecijacija će se događati samo kroz prilagodbu relativnih cijena jer je nominalni tečaj između Hrvatske i partnera iz eurozone fiksiran.

## Optimalno valutno područje i Hrvatska

Još jedan argument pri prosudbi o prelasku na euro je pitanje eurozone kao *optimalnog valutnog područja*[16]. Prema izvornom shvaćanju ove teorije – koje se nadograđivalo drugim kriterijima poput trgovinske i financijske, političke i fiskalne integracije, proizvodnom strukturom i drugim kriterijima – prvi kriterij za to su *simetrični (usklađeni) poslovni ciklusi* jer bi se tada provodila i slična monetarna politika (Mundell, 1961). Dosadašnja istraživanja su uglavnom potvrđivala da su poslovni ciklusi Hrvatske usklađeni s ciklusima u EU[17]. Takav zaključak je sam po sebi razumljiv jer su zemlje eurozone najvažniji hrvatski vanjskotrgovinski partneri i banke iz eurozone vlasnici oko 90% domaće aktive. Na taj način i trgovinski i financijski šokovi iz EU moraju se odražavati i na hrvatsko gospodarstvo. Slični zaključci vrijede i za druge zemlje EU. Međutim, promatrano u cjelini, uvjet simetričnih ciklusa za eurozonu još nije zadovoljen. Ipak, ona još uvijek može biti optimalno valutno područje ako je zadovoljen kriterij *mobilnosti faktora proizvodnje,* a naročito rada. To bi značilo da bi se rad trebao seliti iz područja s visokom nezaposlenošću u područja sa snažnom potražnjom za radom. Populacijsko pražnjenje Hrvatske koje je uslijedilo nakon ulaska u EU nakon 2013. godine možda bi nas navuklo na zaključak da je ovaj uvjet zadovoljen. To bi dodatno mogla učvrstiti migracijska kretanja iz/u drugih europskih zemalja poput Poljske, Latvije, Portugala, Grčke i dr. Kada se govori u kontekstu Hrvatske, to je dugoročni trošak jer se prazne značajna

[16] Više je radova na ovu temu, ali u kontekstu uvođenja eura u Republiku Hrvatsku autorima je jedino znan članak Brkić i Šabić (2018).

[17] Neka istraživanja na tu temu su: Šonje i Vrbanc (2000), Belullo, Šonje i Vrbanc (2000), Jovančević, Arčabić i Globan (2012), Brkić i Šabić (2018), Kunovac, Rodriguez-Palenzuela i Sun (2022) i tamo navedeni radovi.

područja i Kohezijska politika EU teško bi ga mogla spriječiti ili ublažiti[18]. Tijekom povijesti su pusta područja uvijek bila i važan sigurnosni problem. Stoga kriterij mobilnosti radne snage mora podrazumijevati dvostrana kretanja. Svakako da u tom kontekstu na prvo mjesto valja stvarati povratničke tijekove iz inozemstva, i to stanovništva u radno sposobnoj dobi koje svojim znanjem i iskustvom može pomoći unapređenju našega gospodarstva. Iako iseljeništvo doznakama pomaže domicilno stanovništvo (Bogdan i Ivanda, 2019), taj je efekt zanemariv u odnosu na gubitak fertiliteta te trenutne i buduće radne snage. No bez obzira na ova kretanja, kriterij mobilnosti rada kao uvjet za optimalno valutno područje na razini cijele eurozone ipak nije zadovoljen.

Prema opisanim kriterijima, eurozona (još nije) optimalno valutno područje, a vrijeme će pokazati hoće li to postati u budućnosti[19]. Zato monetarna politika ESB-a ne mora uvijek odgovarati podjednako svim članicama eurozone. Vjerojatno to najbolje odražava činjenica da od osam članica EU koje 2021. godine još nisu bile premašile predpandemijsku razinu proizvodnje iz 2019. godine samo jedna nije imala euro kao vlastitu valutu. Ali se zato isticalo da članice EU izvan eurozone postižu veće stope inflacije. Činjenica jest da su 2021. godine najveće stope inflacije bilježile Mađarska (5,2%) i Poljska (5,2%), 2023. godine Mađarska (17%) i Češka (12%), a 2022. godine članice eurozone Estonija (19,4%), Litva (18,9%) i Latvija (17,2%)[20]. Prema tome, obje skupine zemalja već su pogodila inflatorna kretanja tijekom 2022. godine koja su različite snage za različite ekonomije[21], što je primoralo ESB na povećavanja kamatnih stopa između srpnja 2022. i rujna 2023. godine. U predpandemijsko vrijeme politika ESB-a uglavnom je odgovarala Hrvatskoj (Arčabić, 2019). Do 2009. godine, pozitivna kretanja u eurozoni uspješno su se prelijevala i na hrvatsko gospodarstvo. Povoljni financijski uvjeti u Europi su olakšavali dužničko financiranje domaće potražnje u Hrvatskoj i pridonijeli rastu našeg BDP-a, ali i rastu vanjskog i

[18] Ta je tvrdnja osobito istaknuta u Vizek (2019). Nepovoljne demografske posljedice ulaska u EU posebno su naglašene u Akrap (2023) i Akrap i Ivanda (2023).

[19] Primjerice, Pfeifer i Schnabl (2026) utvrđuju da se eurozona ne razvija prema optimalnosti i suočava se s rastućim rizicima osim ako se ne provedu institucionalne reforme ili strukturne promjene.

[20] Tijekom 2024. godine EU ostvaruje inflaciju od 2,6%, a eurozona 2,4%, a 2025. godine ona se smanjuje na 2,5% u EU i 2,1% u eurozoni. No oba puta najveću inflaciju ima Rumunjska (5,8% 2024. i 6,8% 2025.). Hrvatska postiže jednu od većih stopa inflacije u eurozoni.

[21] Ovim državama treba dodati i Mađarsku s inflacijom od 15,3%, Češku (14,8%), Poljsku (13,2%), Bugarsku (13,0%), dok su najniže stope inflacije bile u Švedskoj (8,1%), Finskoj (7,2%), Malti (6,1%) i Francuskoj (5,9%).

javnog duga. Kada je s dužničkom krizom porasla averzija prema riziku, visokozaduženim zemljama poput naše također je pomogla ekspanzivna politika ESB-a jer je pridonosila manjim izdvajanjima za kamate. No Hrvatska se (jer nije bila u eurozoni) morala zaduživati po tržišnim uvjetima, za razliku od Grčke koja je imala niže kamatne stope iako je imala veću zaduženost (udio javnog duga u BDP-u). Pod kapom ESB-a Hrvatska se može nadati povoljnijim zaduženjima nego da je izvan eurozone čak i da se pojavi neka nova dužnička kriza[22].

Ali stopa inflacije može biti kriterij pri usporedbi Hrvatske i eurozone. Uoči same pandemije ona je čak u Hrvatskoj bila niža u odnosu na samu eurozonu (20 zemalja, tj. bez Bugarske). Razdvajanje stopa inflacije zbiva se 2022. (razlika 2,3 postotna boda) i 2023. godine (3,0 bodova), a inflacijski diferencijal ostaje pozitivan i u 2024. (1,6 bodova) i 2025. godini (2,3 boda).[23]

## *Druga argumentacija za / protiv eura*

U skladu sa navedenim, uklonjen tečajni rizik se može uzeti kao korist za Hrvatsku. Tu se može dodati uključivanje glavnih banaka pod nadzor ESB-a, ali su njihovi vlasnici (a posredstvom njih i naše banke) i do sada već bili njime obuhvaćeni[24]. No, zbog visoke kapitaliziranosti naše banke su i do sada prebrođivale i dugotrajnu krizu (2009. – 2014.) i probleme zbog kredita u francima (CHF). Financijska stabilnost je i prije eura pridonosila uspješnom funkcioniranju bankovnog sustava, ali se nerijetko moglo čuti da su domaće banke zbog vlastitog blagostanja često zanemarivale potrebe našeg gospodarstva (Ivanov, 2014). Dodatna integracija naših najvećih banaka u nadzor jedne od svjetski utjecajnih institucija kao što je ESB vjerojatno će unaprijediti njihovu stabilnost. Dok se neki rizici koji se mogu odraziti na razine kamatnih stopa smanjuju ili u potpunosti nestaju (npr. tečajni rizik), dotle s rastućom financijskom integracijom drugi nastaju. Tako ako npr.

[22] Okvir 4 u HNB (2022) upućuje na mogućnost da se već i najava ulaska Hrvatske u europodručje odrazila na trošak zaduživanja Hrvatske, a ranije je to izneseno i u Kunovac i Pavić (2018). A povoljan utjecaj na financiranje države može se u budućnosti preliti i na trošak zaduživanja poduzeća i kućanstava. No ulazak Hrvatske u eurozonu dogodio se u vremenu kada je ESB već počela dizati kamatne stope kao odgovor na rastuću inflaciju.

[23] Prema HNB (2022) razlike u inflaciji između Hrvatske i eurozone treba pripisati različitim kretanjima cijena hrane te cijena usluga i industrijskih proizvoda, dok je utjecaj cijene energije bio slabiji. No značaj imaju i različiti ponderi na pojedine stavke.

[24] Pitanje bankovne unije obrađeno je u HUB Analize br. 34. (2011), HUB Analize br. 41. (2012), HUB Analize br. 45. (2013).

Intesa ili Unicredito zapadnu u gubitke, to može rezultirati i gubitkom povjerenja u domaće banke koje su pod njihovim vlasništvom (Bokan, Grguric, Krznar i Lang, 2010). Drugi rizik koji može nastati u budućnosti je neka kriza koja je slična dužničkoj krizi od prije 10-ak godina. Da nije bilo te krize na ukupnom prostoru EU (sa iznimkom Danske i Švedske), već bi zaživjela monetarna unija. No pokazalo se da je kreiran „sustav s greškom" pa su mnoge postsocijalističke zemlje izgubile inicijativu za priključenje eurozoni. Iako je bio plan da se do 2025. godine taj proces posve završi, Poljska, Češka, Mađarska i Rumunjska su i dalje izvan eurozone, a neke i ne razmišljaju o euru u blisko vrijeme[25].

Prethodno istaknuta korist od manjih kamatnih stopa lako se može pretvoriti u rizik jer bi u mediteranskim zemljama ponovno moglo doći do konjunkture na tržištu nekretnina i uzrokovati krizu sličnu onoj od prije 10-ak godina (Vizek, 2019). Čini se da i podaci s tržišta nekretnina ovakvu tvrdnju i potvrđuju.

Prilikom uvođenja eura isticalo se da bi euro mogao *olakšati međunarodnu razmjenu* kao posljedicu eliminacije tečajnog rizika. Dodatni argument opet sadrži u sebi inflatorna kretanja – očuva li se pozitivna razlika u inflaciji, posljedica će biti realna aprecijacija i narušavanje konkurentnosti hrvatskoga robnog izvoza. Iskustva Hrvatske prije 2009. godine su istovremena pozitivna razlika stope inflacije i aprecijacija kune koja je tečajnu politiku HNB-a činila kontroverznom. Aprecijacija je bila posljedica priljeva inozemne valute u domaći financijski sustav (povrat stranog novca iz tezauracije u bankovnu štednju, inozemno zaduživanje, direktna ulaganja, priljev od izvoza i sl.)

[25] Vidjeti o tome u Deskar-Škrbić i Kunovac (2019). Za ući u eurozonu važni su kriteriji iz Maastrichta za:
- inflaciju: inflacija smije biti maksimalno 1,5 postotnih bodova veća od prosjeka triju najnižih stopa inflacije među zemljama Europske unije;
- dugoročne kamatne stope: dugoročna nominalna kamatna stopa smije biti maksimalno 2 postotna boda veća od prosjeka kamatnih stopa u tri zemlje s najnižom inflacijom u EU-u;
- članstvo u Europskom tečajnom mehanizmu (ERM II): zemlja mora provesti barem dvije godine u ERM II, a kada uđe u ERM II obvezuje se da će fluktuacije vlastite valute držati unutar granica od 15% u odnosu na unaprijed određeni središnji tečaj domaće valute prema euru;
- proračun: maksimalna razina proračunskog deficita je 3% BDP-a, a javnog duga 60% BDP-a.

Od članica EU-27 izvan eurozone su ostale Češka, Danska, Mađarska, Poljska, Rumunjska i Švedska. Švedska je referendumom dvaput odbacila uvođenje eura, a od uvjeta za uvođenje eura zadovoljila je sve osim članstva u ERM II mehanizmu. Danska je jedina ispregovarala ostanak izvan eurozone premda ima sve uvjete za euro. Rumunjska je namjeravala uvesti euro 2026., ali čini se da neće prije 2032. godine, a trenutno zadovoljava samo uvjet o omjeru duga i BDP-a i kretanju tečaja. Prema ECB (2026) Češka i Švedska nemaju uvjet članstva u ERM II, Mađarska zadovoljava jedino uvjet fluktuacija tečaja, dok Poljska i Rumunjska uz taj uvjet zadovoljavaju i uvjet javnog duga.

(Lang i Krznar, 2004). Sigurno je ranih 1990-ih pridonosila smanjenju jako visoke stope inflacije, ali i stagnaciji robnog izvoza u drugoj polovici 1990-ih (Bogdan, 2022b). Iako ni druge europske postsocijalističke zemlje (od 2004. i 2007. članice EU) na početku XXI. stoljeća nisu bile pošteđene realne aprecijacije, dinamika hrvatskoga robnog izvoza u usporedbi s njima je bila najlošija. Realna aprecijacija sigurno će biti snažnija ako pozitivni inflatorni diferencijal prati i nominalna aprecijacija. Premda ova argumentacija više ide u prilog euru, ipak je važniji čimbenik izvoza uključenje u EU 2013. godine. U času priključenja (2011. – 2013.) 61% hrvatskoga robnog izvoza odlazilo je u zemlje EU, a uoči pandemije 2019. rekordnih 68% jer je omogućeno snažnije povezivanje hrvatskih kompanija s ogromnim tržištem od 447 milijuna stanovnika (procjena Eurostata za 1.1.2022. godine). Ali na tako velikom tržištu postoji i velika konkurencija, a s obzirom na to da tu postoje cjenovno jači igrači, tu mogu opstati samo oni koji imaju naglašenu necjenovnu konkurentnost. U početnim stadijima proboja na inozemna tržišta, cijena je svakako važan čimbenik (a s njom i tečaj), ali tijekom vremena neki drugi čimbenici poput kvalitete, unikatnosti, složenosti, inovativnosti i dr. dobivaju na značenju[26]. I na najvažnijem tržištu (EU) Hrvatska još uvijek konkurira cjenovno premda u EU jača potražnja za složenijim proizvodima (Stojčić, Bečić i Vojinić, 2012). Nadalje, prostori u Hrvatskoj koji su najviše izvozno orijentirani su i krajevi s relativno niskim plaćama. Teško je ipak reći da će sam euro značajnije pridonositi izvozu; dapače od 2000. godine do danas izvoz kontinuirano raste unatoč vlastitoj valuti.

Neće to *značajnije pomoći ni našem turizmu* iako sada koristimo istu valutu kao i gosti iz naših najvažnijih emitivnih tržišta (Njemačka, Austrija, Slovenija, Italija) jer neće značajnije utjecati na fizičke i financijske pokazatelje. Do pandemijske krize i uz vlastitu valutu je svaka iduća godina bila rekordna i po fizičkim i po financijskim pokazateljima. Tako je, prema podacima platne bilance (dostupne na internetskoj stranici HNB-a), 2019. godine ostvaren prihod od turizma 10,5 milijardi EUR koji je premašen tek 2022. godine (13,1 milijardi EUR), a 2025. godine je 15,3 milijarde. Svakako rast prihoda od turizma nakon 2022. nije posljedica uvođenja eura, nego privlačnosti Hrvatske kao turističke destinacije (ali i inflacije). Čak, izražena orijentacija na turističku djelatnost može biti i potencijalni trošak uvođenja eura (Brkić i Šabić, 2018). Već iskustvo koronakrize pokazuje da bi hrvatsko

[26] O tome više vidi u: Bogdan i Rogić Dumančić (2016).

gospodarstvo bilo snažno pogođeno kada bi se dogodio neki šok koji bi se posebno odrazio na turizam (npr. politička nestabilnost u jugoistočnoj Europi). Tada bi imalo na raspolaganju samo mjere fiskalne politike da se protiv tog šoka bori dok bi i onako slab efekt monetarne politike u potpunosti iščezao.

Sličan zaključak može se izvesti i za *inozemna ulaganja*. I između 1993. i 2022. godine najveći udio inozemnih ulaganja bila su zaduživanja, a od direktnih ulaganja 21% bilo je u financijskim djelatnostima, a 9% u nekretninama te u prerađivačkoj industriji oko 17%. U međuvremenu je udio ulaganja u financijskim djelatnostima i u ulaganjima u nekretnine dodatno porastao.

Euro vrlo vjerojatno neće značajnije *dugoročno pridonijeti ni hrvatskom standardu* iako se to često ističe. Iz osnova je ekonomske analize poznata neutralnost monetarne politike u dugom roku, ali to nadalje znači da ni valuta nije važna iako su uvijek mogući određeni pozitivni učinci u kratkom roku. U dugom roku je rast životnog standarda određen tehnološkim napretkom. A mi se kao društvo pretežito reklamiramo u dominantno radno intenzivnoj djelatnosti u kojoj do sada nije zabilježen značajniji tehnološki napredak. Dodatno, treba uključiti i demografske izazove s kojima se suočava hrvatsko gospodarstvo. U značajnoj mjeri kao posljedica iseljavanja (ali treba dodati i demografsko starenje), hrvatske se kompanije već sada suočavaju s nedostatkom radne snage kojeg rješavaju uvozom. Dio iseljenih vratit će se u domovinu sa svježe stečenim znanjem i iskustvom, ali već sada možemo razmatrati kako će se demografske promjene odraziti na gospodarski rast i mogu li se nadići tehnološkim napretkom. Još je u Lovrinčević (2019) procijenjeno da bi stopa gospodarskog rasta do 2050. godine mogla biti između 1,1 i 1,9%, što je ipak niže u odnosu na trenutne stope. Čini se da su dugoročne posljedice uvođenja eura ipak zanemarive jer je ključ u faktorima rasta u dugom roku poput kvalitete institucija, ulaganja u istraživanje i razvoj (ili uvoza tehnologije) te formalnog i neformalnog obrazovanja i drugim čimbenicima.

Na sve ovo što je do sada rečeno i uz činjenicu da je uz vlastitu valutu manevarski prostor monetarne politike je i tako bio jako slab, valja naglasiti i da bi zadržavanje vlastite valute podrazumijevalo i rad na deeuroizaciji jer bi to povećavalo šanse monetarne politike da djeluje kontraciklički. Iako su neke politike deeuroizacije bile moguće (ali sa neizvjesnim ishodom), priključenjem u EU njihova isplativost je bila upitna jer je uvođenje eura

„jednog dana“ bilo naša obveza. Sada kada je on uveden, lakše uspoređujemo cijene i plaće s drugim zemljama. Nije nam trebalo puno za shvatiti da vlasnici trgovačkih lanaca u svojim prodajnim centrima u Hrvatskoj neće imati iste cijene i iste plaće kao u matičnim zemljama bez obzira na „nepostojanje granica“, rizika, zastoja i valutnog rizika – jer još kao faktore cijena valja dodati i transportne troškove, konkurenciju (odnosno lokalne monopole) i veličinu subjekata pa i fiskalnu politiku. Šale radi, euro će nam omogućiti da shvatimo koliko smo siromašni.

Do sada smo sud o euru iznosili na razini nacionalnoga gospodarstva. Međutim, ono ne mora biti slično viđenju građana. Je li tome tako, vidjet će se u sljedećoj cjelini.

# 3. PERCEPCIJE I ISKUSTVA GRAĐANA O PROMJENI VALUTE[27]

## Metodološki okvir provedenog anketnog istraživanja

Za potrebe empirijskog dijela ovog rada provedeno je anketno istraživanje s ciljem prikupljanja podataka o tome kako građani Republike Hrvatske doživljavaju uvođenje eura i njegove učinke na svakodnevni život. Istraživanjem se nastojalo ispitati opće stavove ispitanika o prelasku na euro, njihovu percepciju promjena cijena i kupovne moći, praktična iskustva s korištenjem nove valute te mišljenje o prednostima i nedostacima uvođenja eura.

Istraživanje je provedeno tijekom ožujka i travnja 2026. godine, točnije u razdoblju od 10. ožujka do 8. travnja 2026. godine. Podaci su prikupljeni *online* anketnim upitnikom, uz istodobno očuvanje anonimnosti sudionika. Anketa je distribuirana elektroničkim putem, odnosno preko društvenih mreža, aplikacija za komunikaciju i među osobnim kontaktima, pri čemu su ispitanici dobrovoljno pristupali ispunjavanju upitnika.

U istraživanju je sudjelovalo ukupno 158 ispitanika. Uzorak je bio prigodan, što znači da su u istraživanju sudjelovale osobe koje su bile dostupne i spremne ispuniti anketni upitnik. Iako se takav uzorak ne može smatrati potpuno reprezentativnim za cjelokupno stanovništvo Republike Hrvatske, on ipak omogućuje dobivanje korisnog uvida u mišljenja i iskustva dijela građana različitih sociodemografskih obilježja. U istraživanje su uključeni

[27] Ovaj dio je uz prilagodbu preuzet iz Hercezi (2026).

ispitanici različite dobi, spola, obrazovne razine, radnog statusa i mjesta stanovanja, kako bi se obuhvatio što širi raspon stavova i iskustava povezanih s uvođenjem eura.

Upitnik je bio podijeljen u pet tematskih cjelina[28]. Prva cjelina odnosila se na opće podatke o ispitanicima i obuhvaćala je pitanja o spolu, dobi, razini obrazovanja, radnom statusu i mjestu stanovanja. Druga cjelina bila je usmjerena na opće stavove o uvođenju eura, odnosno na to jesu li ispitanici podržavali uvođenje eura, kako danas gledaju na tu odluku i smatraju li da je Hrvatska bila spremna za prelazak na novu valutu. Treća cjelina odnosila se na percepciju cijena i troškova života, odnosno na to jesu li ispitanici primijetili rast cijena, koje su skupine proizvoda i usluga prema njihovu mišljenju najviše poskupjele, kako procjenjuju vlastitu kupovnu moć te u kojoj mjeri promjene cijena utječu na njihovu svakodnevicu. Četvrta cjelina obuhvatila je praktična iskustva s eurom, kao što su privikavanje na novu valutu, navika preračunavanja iznosa iz eura u kune, procjena organiziranosti samog prelaska te korisnost informacija i dvojnog iskazivanja cijena. Peta cjelina odnosila se na prednosti i nedostatke eura.

Što se ograničenja tiče, prije svega, riječ je o prigodnom uzorku pa se rezultati ne mogu bez zadrške generalizirati na cijelo stanovništvo Republike Hrvatske. Osim toga, anketni odgovori temelje se na osobnim procjenama i dojmovima ispitanika, što znači da su po svojoj prirodi subjektivni. To se pokazalo važnim kod pitanja koja se odnose na percepciju rasta cijena, kupovne moći ili opće zadovoljstvo uvođenjem eura, jer se takve procjene mogu razlikovati od osobe do osobe. Unatoč tome, upravo su subjektivni stavovi i iskustva bili u središtu ovog istraživanja pa se takav pristup može smatrati prikladnim s obzirom na temu rada.

## Rezultati i interpretacija podataka ankete

### *Osnovne karakteristike uzorka*

U istraživanju je sudjelovalo 85 žena (53,8%), 69 muškaraca (43,7%), dok 4 ispitanika (2,5%) nisu željela otkriti spol. Prema dobi najviše ispitanika je staro između 18 i 25 (26,6%) te 26 i 35 godina (24,7%). Druga polovica uzorka uključuje ispitanike stare 36 do 45 godina (19,6%), 46 do 55 godina (17,1%) te starije od 55 godina (12,0%). Uzorak je obuhvatio više dobnih

[28] Zbog velikih gabarita ovog rada nismo u mogućnosti predočiti cijeli anketni upitnik.

skupina, pri čemu prevladavaju mlađe osobe. Najveći broj ispitanika ima završenu srednju školu (44,9%), dok 41,8% ima višu školu ili fakultet. Poslijediplomski studij završilo je 7,6% ispitanika, a osnovnu školu 5,7%.

Zatim, većina ispitanika je zaposlena (58,9%). Studenti čine 17,7% uzorka, umirovljenici 10,8%, nezaposleni 8,9%, dok je 3,8% ispitanika označilo ostale statuse. Rezultati pokazuju da u istraživanju prevladavaju radno aktivne osobe. Najveći broj ispitanika živi u gradu (61,4%), zatim u prigradskom području (21,5%), dok 17,1% živi na selu. Time je vidljivo da su u uzorku zastupljeniji stanovnici urbanih sredina.

## *Rezultati ankete*

U *drugoj* sekciji prikazani su stavovi ispitanika o samom uvođenju eura. Ispitivano je jesu li građani podržavali ovu promjenu prije prelaska, kako je procjenjuju danas te smatraju li da je Hrvatska bila spremna za uvođenje zajedničke valute. Najprije se građane pitalo jesu li podržavali uvođenje eura prije same promjene valute te kakav je njihov stav nakon što je euro uveden. (slika 1.). Prije prelaska na euro novu je valutu podržavalo 34,8% ispitanika, protiv je bilo 38,6%, dok 26,6% nije imalo jasan stav Danas najviše ispitanika uglavnom gleda pozitivno na uvođenje eura (31,0%) i s onima s vrlo pozitivnim stavom (13,3%) to je 44% svih ispitanika. Nasuprot njima su oni s uglavnom negativnim (22,8%) i vrlo negativnim stavom (11,4%), što daje 34% svih ispitanika. Preostala skupina stanovnika (21,5%) neutralnog je stava. Kako su pozitivni stavovi nešto izraženiji od negativnih, za očekivati je da većina ispitanika misli da je Hrvatska bila dobro pripremljena za euro (što je bio sljedeći upit), a to potvrđuju i podaci sa slike 2.[29].

[29] Prema tim podacima da je Hrvatska bila spremna smatra 46,8% ispitanika, 32,3% smatra da nije, a 20,9% nije sigurno. Sličan je odnos i kada se vrednuje odluka o uvođenju eura, vidljiv na desnom grafikonu slike 2. Da je riječ o dobrom potezu smatra 45,6% ispitanika, negativan odgovor dalo je 31,0%, a 23,4% odgovorilo je djelomično.

## Slika 1. Podrška euru u Hrvatskoj

PRIJE PRELASKA NA EURO

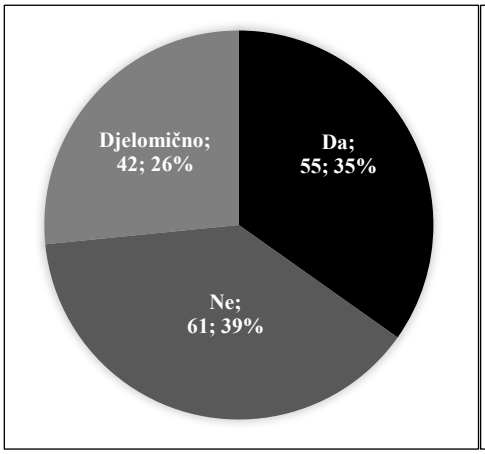


NAKON UVOĐENJA EURA

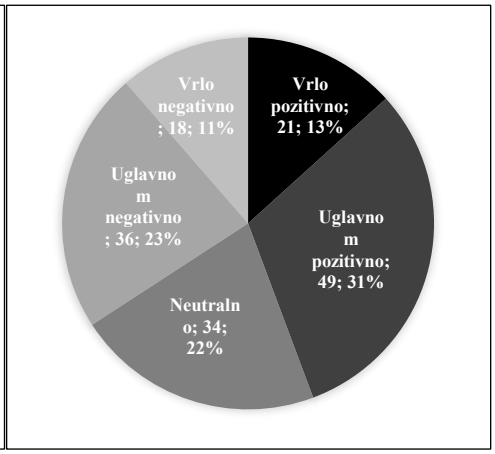


Izvor: Izračun autora.

## Slika 2. Procjena spremnosti Hrvatske i vrednovanje odluke o uvođenju eura prema ispitanicima

SPREMNOST ZA EURO

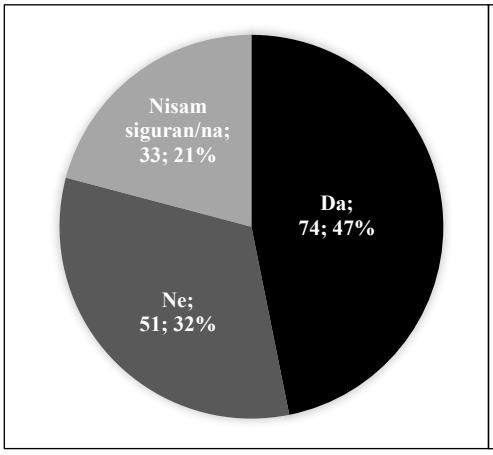


VREDNOVANJE ODLUKE O UVOĐENJU EURA

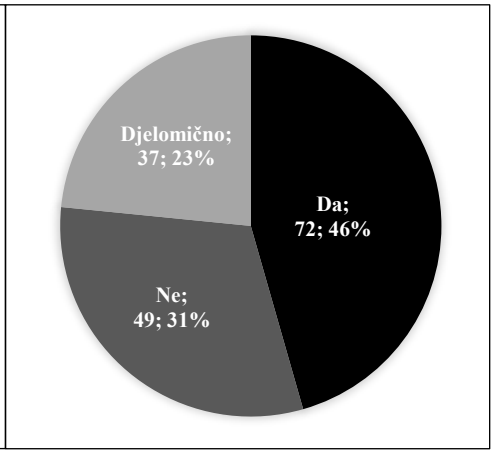


Izvor: Izračun autora.

Budući da je sam proces uvođenja eura bio povezan i sa strahovima građana, posebice za moguć porast cijena, ispitanici su upitani da procijene informiranost prije prelaska na euro i ti su rezultati prikazani na slici 3. Najviše ispitanika smatra da građani nisu bili dovoljno informirani (38,6%). Da jesu smatra 34,8%, dok 26,6% navodi djelomičnu informiranost. Rezultati upućuju na određene rezerve prema informiranju javnosti.

**Slika 3. Procjena informiranosti građana prije prelaska na euro prema odgovorima ispitanika**

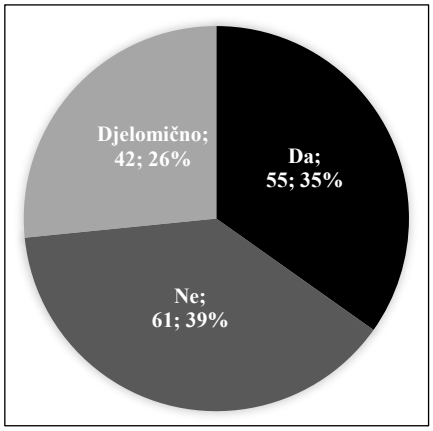


Izvor: Izračun autora.

Zbog straha od utjecaja eura na razinu cijena, *treća* cjelina upitnika odnosila se na promjene koje ispitanici povezuju s cijenama, troškovima života i osobnom financijskom situacijom nakon uvođenja eura. Posebna pažnja usmjerena je na percepciju rasta cijena, kupovne moći i promjene potrošačkih navika. Glede percepcije cijene nakon uvođenja eura najviše ispitanika smatra da su cijene znatno porasle (52,5%), a dodatno 34,2% misli da su cijene djelomično porasle (slika 4.) dok značajno manji udio smatra da se cijene nisu značajno promijenile ili su se čak smanjile. Kako većina ispitanika povezuje uvođenje eura s rastom cijena, potrebno ih je bilo ispitati kod kojih proizvoda i usluga građani najviše primjećuju poskupljenja (slika 5.). Najviše ispitanika navelo je hranu i piće (79,7%), zatim kafiće i restorane (63,9%).

Potom slijede gorivo (46,2%), stanovanje i režije (43,7%), frizerske i druge usluge (36,7%) te odjeća i obuća (23,4%).

**Slika 4. Percepcija promjene cijena nakon uvođenja eura**

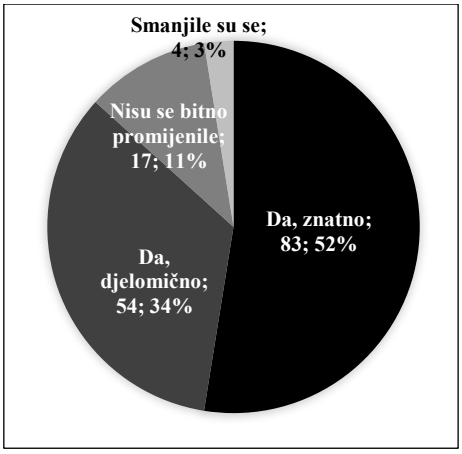


Izvor: Izračun autora.

**Slika 5. Dobra i usluge u kojima su ispitanici primijetili najveći rast cijena**

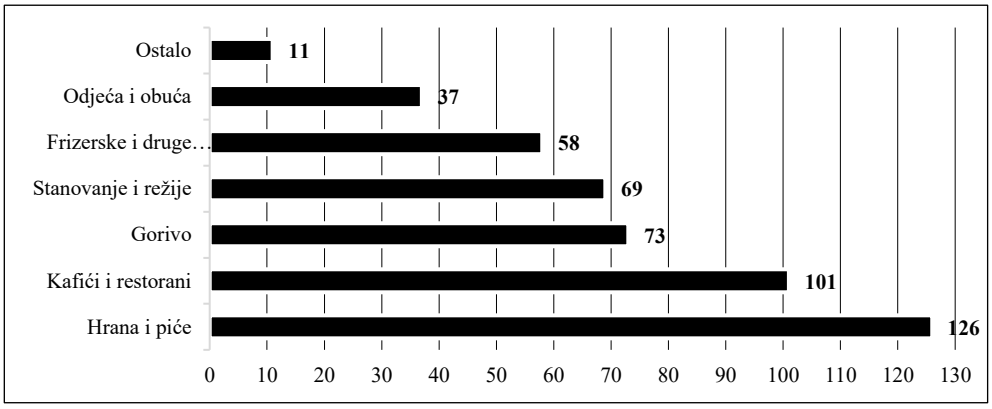


Napomena: Za svaku sastavnicu ukupan broj ispitanika može biti manji od 158. Kako navode više skupina, ukupan zbroj vrijednosti po stupićima znatno je veći od broja ispitanika, pa tortni grafikon nije prikladan.

Izvor: Izračun autora.

**Slika 6. Mišljenje ispitanika o euru kao glavnom razlogu rasta cijena i njihova procjena vlastite kupovne moći nakon uvođenja eura**

EURO KAO GLAVNI UZROK INFLACIJE PROCJENA KUPOVNE MOĆI

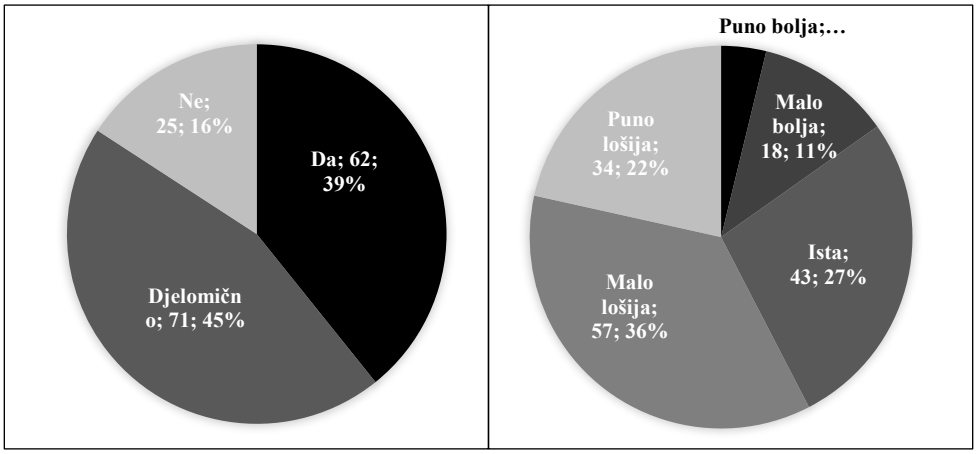


Izvor: Izračun autora.

Nadalje je bilo potrebno utvrditi u kolikoj mjeri ispitanici ova poskupljenja dovode u vezu s eurom. Prema slici 6. najviše ispitanika smatra da je euro djelomično razlog rasta cijena (44,9%), dok 39,2% smatra da je glavni razlog. Samo 15,8% ispitanika ne povezuje euro s rastom cijena. Jasno, očekivano je da će sličan odnos biti i kada procjenjuju vlastitu kupovnu moć nakon uvođenja eura – tako je 58% ocjenjuje malo ili znatno lošijom, a svega 15% malo ili znatno poboljšanom. Donekle je iznenađujuće da 84% ispitanika dovodi euro u vezu s poskupljenjima, a da tek skoro 60% zbog toga svoju kupovnu moć smatra pogoršanom.

**Slika 7. Promjene u ponašanju potrošača nakon uvođenja eura i opterećenost rastom cijena**

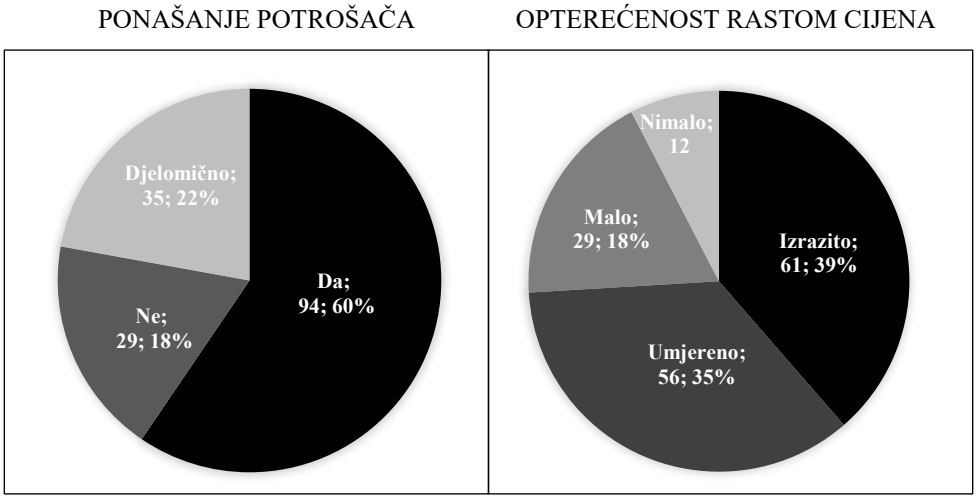


Izvor: Izračun autora.

**Slika 8. Praćenje akcija i popusta nakon uvođenja eura**

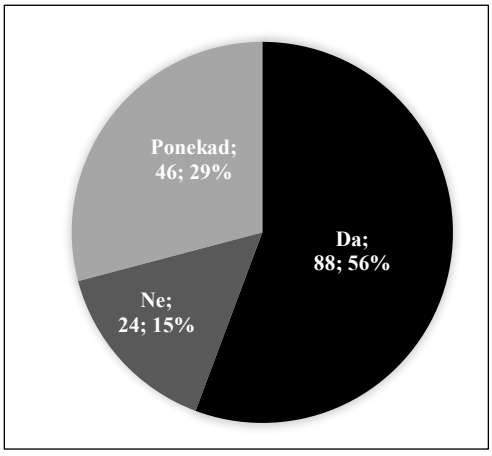


Izvor: Izračun autora.

**Slika 9. Procjena odnosa plaća i rasta cijena**

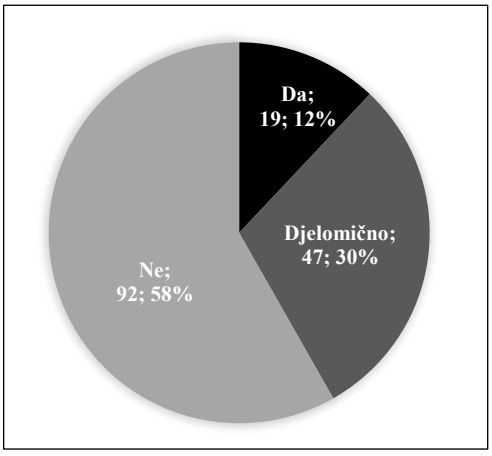


Izvor: Izračun autora.

Imajući u vidu da rezultati slike 6. ipak pokazuju prevladavajući osjećaj pogoršanja financijske situacije, ispitanike se zatim pitalo jesu li nakon

uvođenja eura postali oprezniji u potrošnji, a nakon toga i koliko uvođenje eura utječe na njihov svakodnevni život. Podaci sa slike 7. upućuju na racionalnije upravljanje troškovima: 81,7% ispitanika odgovorilo je da više ili djelomično više paze na potrošnju (lijevi grafikon). Shodno tome na desnom grafikonu najveći udio ispitanika upućuje na određenu opterećenost rastom cijena – tek oko 30% njih signalizira malu opterećenost ili da ih rast cijena ne opterećuje. Najviše ispitanika navodi da ih rast cijena opterećuje izrazito (38,6%) ili umjereno (35,4%). Shodno tome, u idućem pitanju ispitano je jesu li ispitanici promijenili kupovne navike vezane uz praćenje akcija i popusta (slika 8.). Rezultati pokazuju veću osjetljivost građana na cijene jer ih svega 15,2% ne prati više nego ranije. S obzirom na to da je, osim rasta cijena, kupovna moć i pod utjecajem kretanja plaća, građani su u daljnjem pitanju ocijenili jesu li plaće pratile rast cijena. Najveći udio ispitanika iskazao je nezadovoljstvo odnosom primanja i troškova života (slika 9.) smatrajući da plaće nisu pratile rast cijena (58,2%). Od ostalih najveći dio smatra da su plaće djelomično rasle. Shodno tome osjet slabije kupovne moći povezan je s osjećajem nedovoljnog rasta plaća uslijed rasta cijena.

U *idućoj* sekciji prikazana su iskustva građana u svakodnevnom korištenju eura. Naglasak je na prilagodbi novoj valuti, snalaženju pri plaćanju, praćenju cijena i procjeni organizacije samog prelaska. Kod prvog pitanja ispitanici su trebali reći koliko su se brzo priviknuli na novu valutu (slika 10.) i gotovo polovica njih (48,1%) je to brzo učinila, dok je kod preostalih prilagodba bila djelomična (31,0%) ili nije bila brza (20,9%). Brzina privikavanja neposredno je povezana i s navikom preračunavanja eura u kune koja je bila tema idućeg pitanja. Prema slici 11. udio onih koji su se brzo priviknuli na novu valutu značajno je veći od udjela onih koji rijetko ili nikako ne preračunavaju eure u kune (ukupno 41,2%). Navika razmišljanja u kunama još uvijek postoji kod dijela anketiranih (58,9%) bilo da to čini ponekad (34,2%) ili često (24,7%). Međutim, polovica ispitanih smatra da je bio dobro organiziran (odgovori „DA“ – 52%), dok ostali smatraju da je bio djelomično dobro organiziran (29,1%) ili im je odgovor negativan (19%) (slika 12.). U tom kontekstu posebno je bilo važno utvrditi korisnost dvojnog iskazivanja cijena koju je potvrdilo gotovo 2/3 ispitanih (65,2%) (slika 13.). S njima se ne slaže tek 12,0% onih čiji je stav negativan dok preostali (22,8%) smatraju da im je dvojno iskazivanje cijena djelomično pomoglo. Potom se ispitanike pitalo za moguće poteškoće u svakodnevnom korištenju eura i 75,3% nije ih potvrdilo (slika 14.). Da se većina s vremenom prilagodila novom načinu izražavanja cijena pokazuje i 61,4% ispitanika koji potvrđuju da danas lakše prate cijene

nego u razdoblju neposredno nakon uvođenja eura (slika 15.). Ostatak su oni koji misle da je situacija ista (20,9%) ili da im nije lakše nego ranije (17,7%).

**Slika 10. Privikavanje građana na euro**

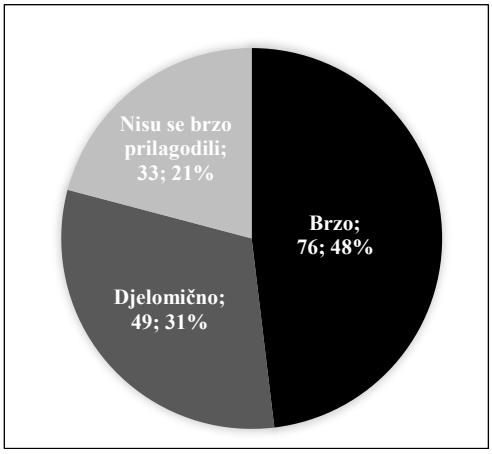


**Slika 11. Navika preračunavanja eura u kune**

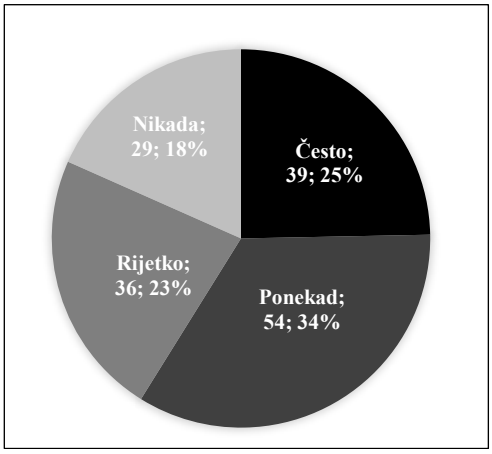


Izvor: Izračun autora.

**Slika 12. Procjena organizacije prelaska na euro**

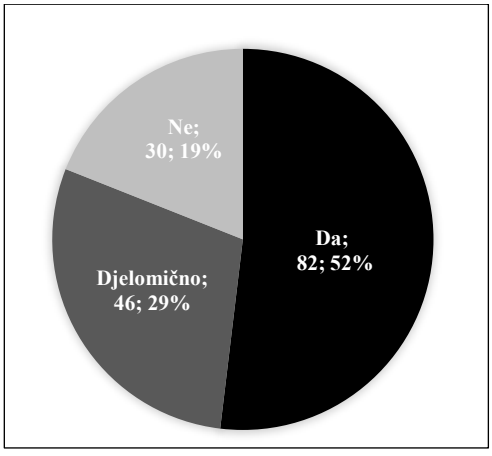


Izvor: Izračun autora.

**Slika 13. Korisnost dvojnog iskazivanja cijena**

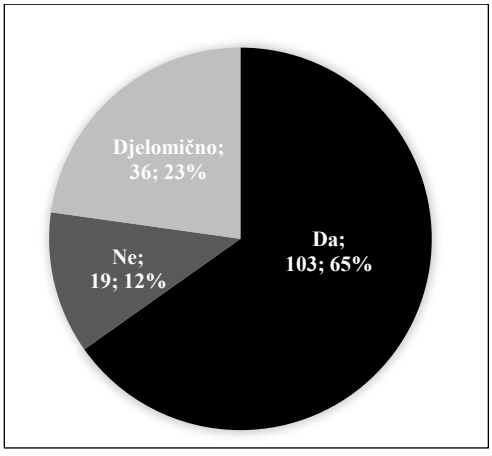


Izvor: Izračun autora.

**Slika 14. Svakodnevno korištenje eura bez poteškoća**

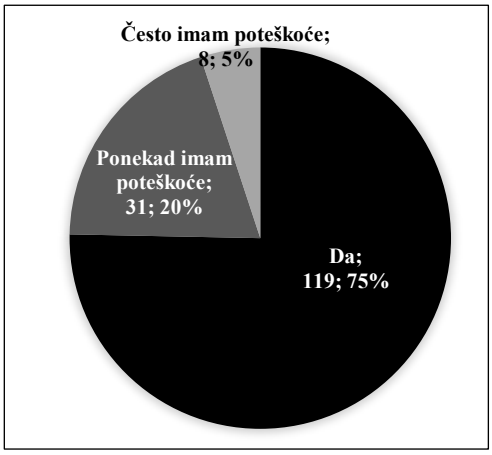


Izvor: Izračun autora.

**Slika 15. Percepcija prilagodbe na praćenje cijena u EUR**

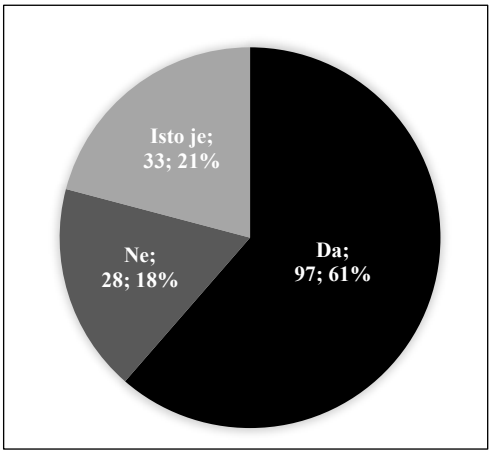


Izvor: Izračun autora.

**Slika 16. Najveće prednosti i nedostaci eura prema mišljenju ispitanika**

PREDNOSTI

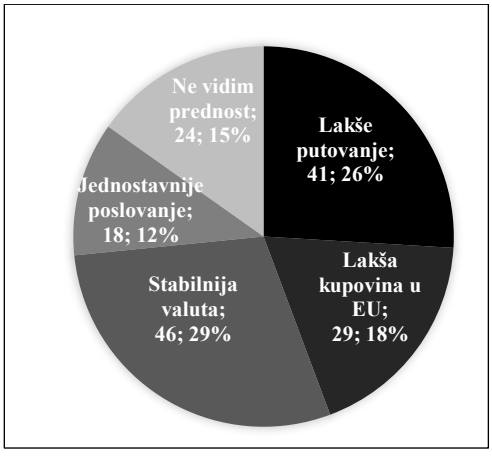


NEDOSTACI

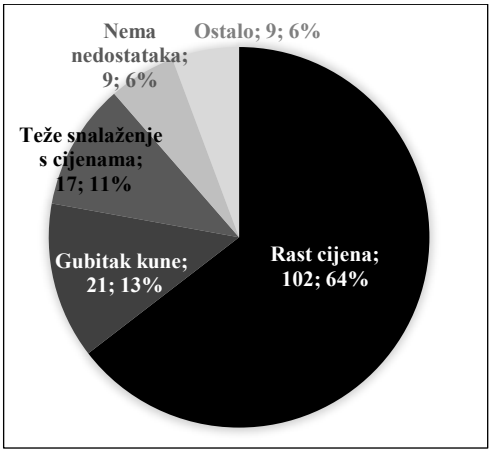


Izvor: Izračun autora.

**Slika 17. Procjena praktičnih koristi eura u inozemstvu**

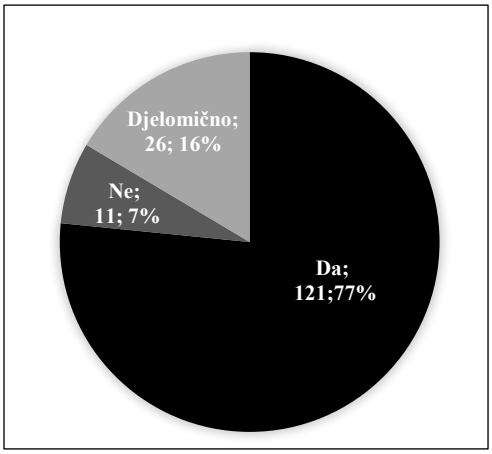


Izvor: Izračun autora.

**Slika 18. Procjena utjecaja eura na financijsku sigurnost**

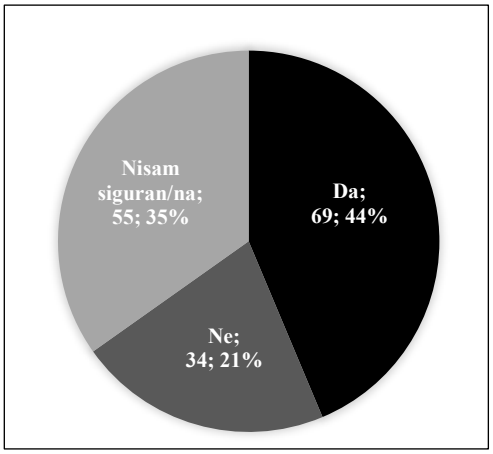


Izvor: Izračun autora.

U *posljednjoj* sekciji prikazani su stavovi ispitanika o glavnim prednostima i nedostacima eura. Ispitivano je koje koristi građani najviše prepoznaju, što smatraju najvećim problemima te kako procjenjuju šire učinke zajedničke valute. Istražujući prednosti eura primjećuje se da građani najviše ističu praktične i financijske koristi (slika 16.) – naime najviše ispitanika navelo je stabilniju valutu (29,1%) te lakše putovanje (25,9%), dok su ostali razlozi: lakša kupovina u Europskoj uniji (18,4%) i jednostavnije poslovanje (11,4%). Preostalih 15,2% ispitanika u euru ne vidi posebnu prednost. Nasuprot tome, rast cijena jasno se izdvaja kao glavni problem u percepciji građana (64,6%), dok manji udio ispitanika navodi gubitak kune (13,3%) i teže snalaženje s cijenama (10,8%). Preostali ispitanici navode druge odgovore ili smatraju da nema nedostataka eura (ukupno 11,3%). Ispitanike se također pitalo prepoznaju li praktične koristi eura izvan Hrvatske i gotovo zanemariv udio ih ne uočava (7%) (slika 17.). Glavnina ih smatra da euro olakšava putovanja i plaćanja u inozemstvu (76,6%), a neki smatraju i da su koristi od eura u inozemstvu djelomične (16,5%). Odgovarajući na pitanje o utjecaju eura na financijsku sigurnost države (slika 18.), najveći udio ispitanika daje pozitivan odgovor (43,7%), ali postoji i značajna sumnja glede učinaka na financijsku sigurnost s obzirom na to da 34,8% ispitanika nije sigurno, a 21,5% smatra da euro ne povećava financijsku sigurnost. Naposljetku, posljednjim pitanjem u anketnom upitniku pitalo se ispitanike

povezuju li uvođenje eura s gubitkom dijela nacionalnog identiteta. Rezultati za ovo pitanje prikazani na slici 19. upućuju na značajnu podijeljenost među ispitanicima. 39,9% anketiranih ne smatra da je došlo do takvoga gubitka, ali je udio onih koji smatraju da je izgubljen dio identiteta (29,7%) i da je takav gubitak samo djelomičan (30,4%) gotovo podjednak.

**Slika 19. Percepcija utjecaja eura na nacionalni identitet**

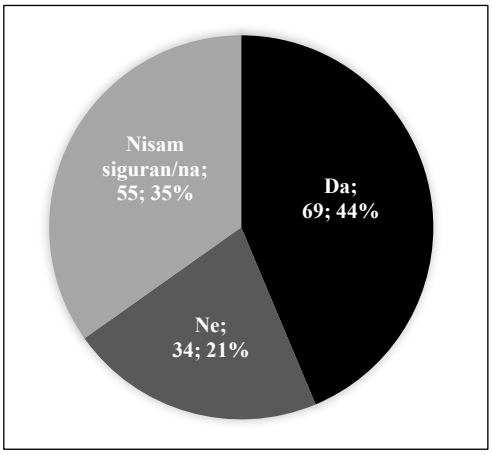


Izvor: Izračun autora.

## *Komentari dobivenih rezultata*

Rezultati pokazuju da su stavovi građana o uvođenju eura uglavnom podijeljeni, ali se može uočiti nekoliko jasnih obrazaca. Iako je dio ispitanika još prije prelaska podržavao uvođenje eura, a i danas nešto veći broj na euro gleda pozitivno nego negativno, odgovori ipak pokazuju da među građanima i dalje postoji određena zadrška. To se posebno vidi u pitanjima koja se odnose na informiranost, rast cijena i osobni osjećaj financijske sigurnosti. Euro je kod dijela ispitanika prihvaćen kao korisna i možda nužna promjena, ali ne i kao promjena bez negativnih posljedica. Zato se može reći da su stavovi građana više praktični nego ideološki. Ispitanici prepoznaju određene koristi eura, ali svoju konačnu procjenu najviše temelje na onome što osjećaju u svakodnevnom životu.

Posebno se ističe povezanost eura s percepcijom rasta cijena. Velika većina ispitanika navodi da su cijene nakon uvođenja eura porasle, a najviše se to primjećuje kod hrane i pića, ugostiteljskih usluga, goriva te stanovanja i režija. To su troškovi s kojima se građani susreću gotovo svaki dan, pa je razumljivo da su upravo oni najviše utjecali na ukupni dojam o novoj valuti. Kada se tome doda podatak da većina ispitanika smatra kako plaće nisu pratile rast cijena, jasno je zašto prevladava osjećaj slabije kupovne moći i veće opterećenosti svakodnevnim troškovima. Iz rezultata se zato vidi da građani uvođenje eura ne promatraju samo kroz samu promjenu valute nego i kroz širi dojam poskupljenja i pritiska na kućni budžet. Taj osjećaj poskupljenja stoga dominira u ukupnoj procjeni eura kod dijela ispitanika.

Rezultati također pokazuju da su se građani u praktičnom smislu uglavnom uspješno prilagodili euru. Većina ispitanika navodi da su se relativno brzo priviknuli na novu valutu, da euro danas koriste bez većih poteškoća i da lakše prate cijene nego odmah nakon prelaska. To znači da su tehnički i organizacijski aspekti prelaska uglavnom dobro prihvaćeni. Korisnost dvojnog iskazivanja cijena dodatno potvrđuje da su prijelazne mjere olakšale prilagodbu građana. Ipak, činjenica da dio ispitanika još uvijek preračunava iznose u kune pokazuje da potpuna psihološka prilagodba nije završena kod svih. Stara valuta i dalje kod nekih građana ostaje referentna točka za procjenu vrijednosti, što je i očekivano kada se radi o promjeni koja izravno utječe na svakodnevne financijske navike.

Kada se promatraju prednosti i nedostaci eura, vidi se da ispitanici najviše prepoznaju njegove praktične koristi, osobito stabilniju valutu, lakša putovanja i lakše plaćanje u inozemstvu. S druge strane, kao glavni nedostatak uvjerljivo se izdvaja rast cijena. To pokazuje da ispitanici euro posve ne odbacuju, nego ga procjenjuju dvostruko: kao koristan u širem ekonomskom i europskom kontekstu, ali problematičan na razini osobne potrošnje. Zanimljivo je i da su mišljenja podijeljena oko pitanja nacionalnog identiteta, što znači da se za dio građana gubitak kune ipak ne svodi samo na ekonomsku nego i na simboličku promjenu. Rezultati istraživanja upućuju na to da građani euro prihvaćaju kao stvarnost s određenim prednostima, ali i dalje zadržavaju kritičan stav zbog dojma da je promjena valute bila praćena rastom životnih troškova i slabljenjem osobnog standarda.

Usporedba rezultata ankete s poglavljem o učincima eura na cijene i kupovnu moć pokazuje zanimljivu razliku između objektivnih ekonomskih pokazatelja i subjektivnog doživljaja građana. Rast cijena nije počeo tek uvođenjem eura,

nego već tijekom 2022. godine, pod utjecajem globalne inflacije, rasta cijena energije, poremećaja u opskrbi i rata u Ukrajini. Također, prikazani podaci pokazuju da euro nije bio glavni uzrok ukupne inflacije, nego se njegovo uvođenje vremenski poklopilo s razdobljem kada su cijene već snažno rasle. S druge strane, rezultati ankete pokazuju da velik broj ispitanika ipak upravo euro povezuje s rastom cijena, bilo kao glavni bilo kao djelomični razlog. To znači da građani svoju procjenu najviše temelje na svakodnevnom iskustvu kupnje, a manje na širem makroekonomskom kontekstu.

Slična razlika vidi se i kod kupovne moći. U Dodatku rada (slika 22.) prikazano je da je 2022. godine došlo do pada realne vrijednosti plaća, ali da su od 2023. godine nadalje plaće rasle brže od cijena pa se kupovna moć počela oporavljati. Dakle, prema statističkim pokazateljima nije došlo do trajnog pada standarda, nego do jačeg kratkoročnog udara nakon kojeg je uslijedio oporavak. U anketi većina ispitanika navodi da im je kupovna moć nakon uvođenja eura lošija, da više paze na potrošnju, češće prate akcije i popuste te da plaće nisu pratile rast cijena. Iz toga se može zaključiti da se percepcija građana ne podudara u potpunosti s prikazanim ekonomskim pokazateljima. Iako podaci upućuju na postupnu stabilizaciju i oporavak, među građanima je i dalje snažno prisutan osjećaj da su troškovi života porasli brže nego njihova primanja.

# 4. ZAKLJUČAK

Uvođenje eura u Republici Hrvatskoj bilo je jedna od važnijih gospodarskih promjena u posljednjim godinama. Ulaskom u eurozonu Hrvatska je postala dio zajedničkoga monetarnog sustava Europske unije, a kuna je zamijenjena eurom. Ta promjena nije značila samo novu valutu u optjecaju nego je utjecala i na poslovanje poduzeća, financijski sustav, potrošnju građana i svakodnevni život stanovništva.

Analitički dio rada pokazao je da rast cijena nakon uvođenja eura nije nastao samo zbog same promjene valute. Na inflaciju su snažno utjecali i drugi čimbenici, kao što su rast cijena energije, posljedice pandemije, problemi u opskrbi te rat u Ukrajini. Najveći rast cijena pojavio se još prije uvođenja eura, dok su se kasnije inflacijski pritisci počeli smanjivati. Podaci o plaćama također pokazuju da su nakon početnog rasta cijena primanja građana počela rasti brže, pa se dio izgubljene kupovne moći postupno vratio. Zbog toga se može zaključiti da euro nije bio glavni uzrok inflacije niti trajnog pada

standarda građana. S druge strane, rezultati ankete pokazali su da građani situaciju doživljavaju drukčije od onoga što prikazuju statistički podaci. Velik broj ispitanika smatra da su cijene nakon uvođenja eura porasle, posebno kod hrane, pića, goriva, režija i ugostiteljskih usluga. Većina ispitanika navela je da plaće nisu dovoljno pratile rast troškova života te da danas više paze na potrošnju, češće prate akcije i popuste te opreznije troše novac. To pokazuje da je osobni osjećaj financijske sigurnosti građanima važniji od samih statističkih pokazatelja.

Iako su mnogi ispitanici istaknuli rast cijena kao glavni problem, prepoznate su i određene prednosti eura. Najčešće se navode stabilnija valuta, lakša putovanja, jednostavnije plaćanje u inozemstvu i bolja povezanost s europskim tržištem. Većina ispitanika navela je i da se s vremenom prilagodila novoj valuti te da euro danas koristi bez većih poteškoća. To pokazuje da je tehnički prijelaz na novu valutu proveden uspješno.

Na kraju se može zaključiti da uspješnost uvođenja eura ne ovisi samo o ekonomskim pokazateljima nego i o tome kako građani žive i kako doživljavaju vlastiti standard. Sama promjena valute ne može riješiti sve gospodarske probleme, ali može stvoriti stabilnije uvjete za razvoj. Daljnji učinci eura ovisit će o kretanju plaća, inflacije i kvaliteti ekonomske politike u godinama koje dolaze.

# LITERATURA

Akrap, A. (2023). Demografske promjene u Hrvatskoj kao zahtjev općega dobra. U S. Baloban, S. Migles i D. Petrović – Štefanac (ur.), *Opće dobro u crkvenom i društvenom životu u Hrvatskoj* (str. 239-265). Zagreb: Centar za promicanje socijalnog nauka Crkve, Katolički bogoslovni fakultet Sveučilišta u Zagrebu i Kršćanska sadašnjost.

Akrap, A. i Ivanda, K. (2023). Prvih deset godina članstva Republike Hrvatske u Europskoj uniji: demografske promjene u Hrvatskoj 2013. – 2023. *Hrvatska revija, 23*(2), str. 14-18. Preuzeto iz https://www.matica.hr/hr/760/prvih-deset-godina-clanstva-republike-hrvatske-u-europskoj-uniji-demografske-promjene-u-hrvatskoj-20132023-35132/

Arčabić, V. (6. veljače 2019). *Bi li Europska centralna banka vodila politiku koja bi Hrvatskoj odgovarala? Što ako ne bi?* Preuzeto 10. ožujka 2022. iz ideje.hr: https://ideje.hr/bi-li-europska-centralna-banka-vodila-politiku-koja-bi-hrvatskoj-odgovarala-sto-ako-ne-bi/

Belullo, A., Šonje, V. i Vrbanc, I. (2000). Je li srednja Europa optimalno valutno područje? *HNB: Istraživanja, I – 8*.

Blanchard, O. J., Amighini, A. i Giavazzi, F. (2010). *Macroeconomics: A European Perspective* (1st Edition). Harlow: Prentice Hall.

Bogdan, Ž. (2021). Komparativna analiza inflacije u Postcovid razdoblju – može li se ocijeniti problematičnom? U J. Tica i K. Bačić (ur.), *29. tradicionalno savjetovanje: Ekonomska politika Hrvatske u 2022. – Postpandemijski izazovi* (str. 37-74). Zagreb: Hrvatsko društvo ekonomista i Inženjerski biro d.o.o.

Bogdan, Ž. (2022a). Inflacijska dinamika u Hrvatskoj i u eurozoni sa naglaskom na postcovid razdoblje. U K. Bačić i M. Klindžić (ur.), *30. tradicionalno savjetovanje: Ekonomska politika Hrvatske u 2023.* (str. 20-55). Opatija: Hrvatsko društvo ekonomista i Inženjerski biro d.o.o. Zagreb.

Bogdan, Ž. (2022b). Konkurentnost hrvatskog izvoza. U A. Obadić i T. Gelo (ur.), *Zbornik radova Utjecaj pandemije na hrvatsko gospodarstvo – dvije godine poslije* (str. 147-163). Zagreb: Ekonomski fakultet Sveučilišta u Zagrebu.

Bogdan, Ž. i Ivanda, K. (2019). The impact of personal remittances from abroad on the Croatian economy. U M. Leko-Šimić i B. Crnković (ur.),

*Proceedings of 8th International Scientific Symposium „Economy of eastern Croatia – vision and growth"* (str. 19-29). Osijek: Faculty of Economics – Osijek.

Bogdan, Ž. i Rogić Dumančić, L. (2016). Konkurentnost hrvatskoga gospodarstva. U A. Obadić i J. Tica (ur.), *Gospodarstvo Hrvatske* (str. 110-141). Zagreb: Ekonomski fakultet Sveučilišta u Zagrebu.

Bokan, N., Grguric, L., Krznar, I. i Lang, M. (2010). Utjecaj financijske krize i reakcija monetarne politike u Hrvatskoj . *Istraživanja – Hrvatska narodna banka – I-25*.

Brkić, M. i Šabić, A. (2018). Je li euro optimalna valuta za Hrvatsku – ocjena korištenjem teorije optimalnih valutnih područja. *Privredna kretanja i ekonomska politika, 27*(1(142)), str. 9-70. doi:10.15179/pkiep.27.1.1

Buchen, T. i Wollmershäuser, T. (2016). Exchange Rate Policy. U O. Falck i S. Schönherr, *An Economic Reform Agenda for Croatia* (str. 27-51). München: IFO Forschungberichte 70.

Deskar-Škrbić, M. i Kunovac, D. (2019). Dvadeseta godišnjica eura: zašto se neke zemlje još ne žele pridružiti. *HNB Pregledi, P-49*.

ECB. (lipanj 2026). *Euro Convergence Report*. Dohvaćeno iz ECB: https://www.ecb.europa.eu/press/other-publications/convergence/html/ecb.cr202606~30e75ae1c2.en.html

European Commission. (Summer 2022). *Standard Eurobarometer 97.* Preuzeto 15. lipnja 2023. iz Summer Eurobarometer, str 3: https://europa.eu/eurobarometer/surveys/detail/2693

Falagiarda, M., Gartner, C., Mužić, I. i Pufnik, A. (07. ožujka 2023). *Has the euro changeover really caused extra inflation in Croatia?* Preuzeto 10. ožujka 2024. iz The ECB blog: https://www.ecb.europa.eu/press/blog/date/2023/html/ecb.blog.230307~1669dec988.en.html

Faulend, M. (2014). *Dolarizacija sa posebnim osvrtom na ciljanje inflacije – doktorska disertacija.* Zagreb: Ekonomski fakultet Zagreb.

Hercezi, D. (2026). *Uvođenje eura u Republici Hrvatskoj i percepcija njegovih učinaka među građanima – završni rad.* Zagreb: Sveučilište u Zagrebu Ekonomski fakultet.

HNB. (2022). *Makroekonomska kretanja i prognoze br. 13*. Zagreb: Hrvatska narodna banka.

HNB. (2026). *Bilten br. 308.* Zagreb: Hrvatska narodna banka.

HUB. (2014). *Pogrešna tumačenja principa upravljanja bilancom banaka i valutnim rizikom*. Preuzeto 01. kolovoza 2016. iz HUB: https://www.hub.hr/hr/pogresna-tumacenja-principa-upravljanja-bilancom-banaka-i-valutnim-rizikom

HUB Analize br. 34. (2011). *Kad države bankrotiraju: izgradnja nove arhitekture financijske stabilnosti u Eurozoni.* Zagreb: Hrvatska udruga banaka i Arhivanalitika.

HUB Analize br. 41. (2012). *Nova europska arhitektura financijske stabilnosti: učvršćivanje temelja.* Zagreb: Hrvatska udruga banaka i Arhivanalitika.

HUB Analize_br. 45. (2013). *Ujedinjeni nadzor banaka pod okriljem ECB-a i nova pravila preustroja banaka u EU.* Zagreb: Hrvatska udruga banaka i Arhivanalitika.

Ivanac, F., Kunovac, D. i Nadoveza, O. (29. kolovoza 2024). *Kako porast plaća utječe na inflaciju.* Preuzeto 07. 07. 2025. iz HNBlog: https://www.hnb.hr/-/kako-porast-placa-utjece-na-inflaciju

Ivanov, M. (2014). Kontraciklična monetarna politika u Hrvatskoj. U G. Družić i I. Družić (ur.), *Razvojni potencijali hrvatskog gospodarstva* (str. 77-98). Zagreb: Hrvatska akademija znanosti i umjetnosti (HAZU) i Ekonomski fakultet Sveučilišta u Zagrebu.

Ivanov, M., Tkalec, M. i Vizek, M. (2011). Determinants of financial euroization in a post-transition country: Do threshold effects matter? *Finance a úvěr: Czech journal of economics and finance, 61*(3), str. 230-251.

Jovančević, R., Arčabić, V. i Globan, T. (2012). Prijenos poslovnih ciklusa zemalja Europske unije na Republiku Hrvatsku. *Ekonomski pregled, 63*(1-2), str. 3-21.

Kolar-Dimitrijević, M. (2013). *Povijest novca u Hrvatskoj – od 1527. do 1941.* Zagreb: Hrvatska narodna banka.

Kožić, I., Sorić, P. i Sever, I. (2024). Assessing the Tourism-Led Inflation Hypothesis: An Empirical Framework. *Tourism: An International Interdisciplinary Journal, 72*(4), str. 524-537. doi:10.37741/t.72.4.1

Kunovac, D. i Pavić, N. (2018). Može li uvođenje eura u Hrvatskoj sniziti trošak zaduživanja? *Privredna kretanja i ekonomska politika, 27*(1 (142)), str. 71-94. doi:10.15179/pkiep.27.1.2

Kunovac, D., Batušić, I. i Čorak, J. (28. travnja 2026). *Vino i čokolada: kakva je veza globalnih poremećaja s domaćim cijenama hrane?* Preuzeto 1. rujna 2026. iz HNBlog: https://www.hnb.hr/-/vino-i-cokolada-kakva-je-veza-globalnih-poremecaja-s-domacim-cijenama-hrane

Kunovac, D., Rodriguez-Palenzuela, D. i Sun, Y. (2022). *A new optimum currency area index for the euro area,.* Dohvaćeno iz European Central Bank,: https://data.europa.eu/doi/10.2866/59530

Lang, M. i Krznar, I. (2004). Transmission Mechanism of Monetary Policy in Croatia. *10th Dubrovnik Economic Conference.* Dubrovnik: Hrvatska narodna banka. Preuzeto 20. travnja 2010. iz https://www.hnb.hr/documents/20182/120763/lang-krznar.pdf/c8fca7fb-be89-4daf-8ca3-91f528605b11

Lovrinčević, Ž. (2019). Ovisi li dugoročni gospodarski rast Hrvatske o demografiji ili ipak proizvodnosti? *Ekonomski pregled, 70*(3), str. 380-410.

Martinis, A. (17. lipnja 2020). *Euroizacija u doba krize*. Preuzeto 16. veljače 2024. iz HNBlog: https://www.hnb.hr/-/euroizacija-u-doba-krize

Mijatović, K. i Bogdan, Ž. (2022). Uvođenje eura kao službene valute u Republici Hrvatskoj . U K. Bačić i M. Klindžić (ur.), *Ekonomska politika Hrvatske u 2023.* (str. 154-176). Zagreb: Hrvatsko društvo ekonomista i Inženjerski biro.

Milinović, A. (2002). Hrvatska novčarska baština. *Hrvatska revija*(2), str. 41-48. Dohvaćeno iz Hrvatska revija: https://www.matica.hr/hr/326/HRVATSKA%20NOV%C4%8CARSKA%20BA%C5%A0TINA/

Mundell, R. A. (1961). A Theory of Optimum Currency Areas. *American Economic Review, 51*(4), str. 657-665.

Mužić, I. i Žilić, I. (19. studenog 2024). *Jesu li cijene u Hrvatskoj zaista više nego u razvijenijim zemljama? Detaljniji pogled na cijene u maloprodajnom lancu.* Preuzeto 8. srpnja 2026. iz HNBlog: https://www.hnb.hr/-/jesu-li-cijene-u-hrvatskoj-zaista-vise-nego-u-razvijenijim-zemljama-detaljniji-pogled-na-cijene-u-maloprodajnom-lancu

Nadoveza, O. (2025). Do increases in public sector wages affect inflation? *Public Sector Economics, 49*(1), str. 1-44. doi:10.3326/pse.49.1.1

Nadoveza Jelić, O. i Ravnik, R. (2022). Ovisni o euru: makroekonomski učinci tečajnih promjena u Hrvatskoj. *HNB Istraživanja*(I-65), str. 1-54.

Pfeifer, M. i Schnabl, G. (2026). The Euro as an Optimum Currency Area? A Reappraisal. *CESifo Working Papers No. 12675,*. doi:10.65864/tpv28k15th

Rogić Dumančić, L., Raguž Krištić, I., i Rogić Kovač, I. (2022). Komparativna analiza inflacije u Hrvatskoj i odabranim zemljama EU. U K. Bačić i M. Klindžić (ur.), *30 tradicionalno savjetovanje: Ekonomska politika Hrvatske u 2023.* (str. 56-81). Zagreb: Hrvatsko društvo ekonoomista i Inženjerski biro d.o.o.

Sorić, P. (2024). The Euro and Croatian Inflation: Much Ado About Nothing? *Public Sector Economics, 48*(1), str. 1-37.

Stojčić, N., Bečić, M. i Vojinić, P. (2012). The Competitiveness of Exports from Manufacturing Industries in Croatia and Slovenia to the EU-15 Market: A Dynamic Panel Analysis. *Croatian Economic Survey, 14*(1), str. 69-105.

Šonje, V. i Vrbanc, I. (2000). Mjerenje sličnosti gospodarskih kretanja u srednjoj Europi: povezanost poslovnih ciklusa Njemačke, Mađarske, Češke i Hrvatske. *Ekonomski pregled, 51*(9-10), str. 895-917.

Tkalec, M. (2012). The Dynamics of Deposit Euroization in European Post-transition Countries : Evidence from Threshold VAR. *Czech Journal of Economics and Finance, 62*(3), str. 278-296.

Tkalec, M. i Verbič, M. (2013). A new look into the prevalence of balance sheet or competitiveness effect of exchange rate depreciation in a highly euroized economy. *Post-communist economies, 25*(2), str. 225-240. doi:10.1080/14631377.2013.787755

Tkalec, M. i Žilić, I. (27. svibnja 2025). *Iste cijene za sve? Što nam govore novi podaci o trgovinama diljem Hrvatske.* Preuzeto 12. srpnja 2026. iz Ekonomski institut: https://eizg.hr/iste-cijene-za-sve-sto-nam-govore-novi-podaci-o-trgovinama-diljem-hrvatske/7228

Tkalec, M. i Žilić, I. (26. veljače 2026). *Turizam i promjene cijena u maloprodaji.* Preuzeto 10. srpnja 2026 iz Ekonomski institut: https://eizg.hr/turizam-i-promjene-cijena-u-maloprodaji/7512

Vizek, M. (7. siječnja 2019). *Svi tvrde da smo spremni uvesti euro. Znate li koliko to košta i čime ćete to platiti?* Preuzeto 30. siječnja 2019. iz t-portal.hr:

https://www.tportal.hr/komentatori/clanak/svi-tvrde-da-smo-spremni-uvesti-euro-znate-li-koliko-to-kosta-i-cime-cete-to-platiti-foto-20190107

Vizek, M. (16. kolovoza 2023). *Da, hrana je ekstremno poskupjela. No jesmo li s pravom bijesni na proizvođače*. Preuzeto 17. kolovoza 2023. iz t-portal: https://www.tportal.hr/komentatori/clanak/poskupljenje-hrane-komentar-maruska-vizek-foto-20230816

# DODATAK

## Slika 20. Doprinosi inflaciji mjerenoj postotnom promjenom harmoniziranog indeksa potrošačkih cijena (HICP)

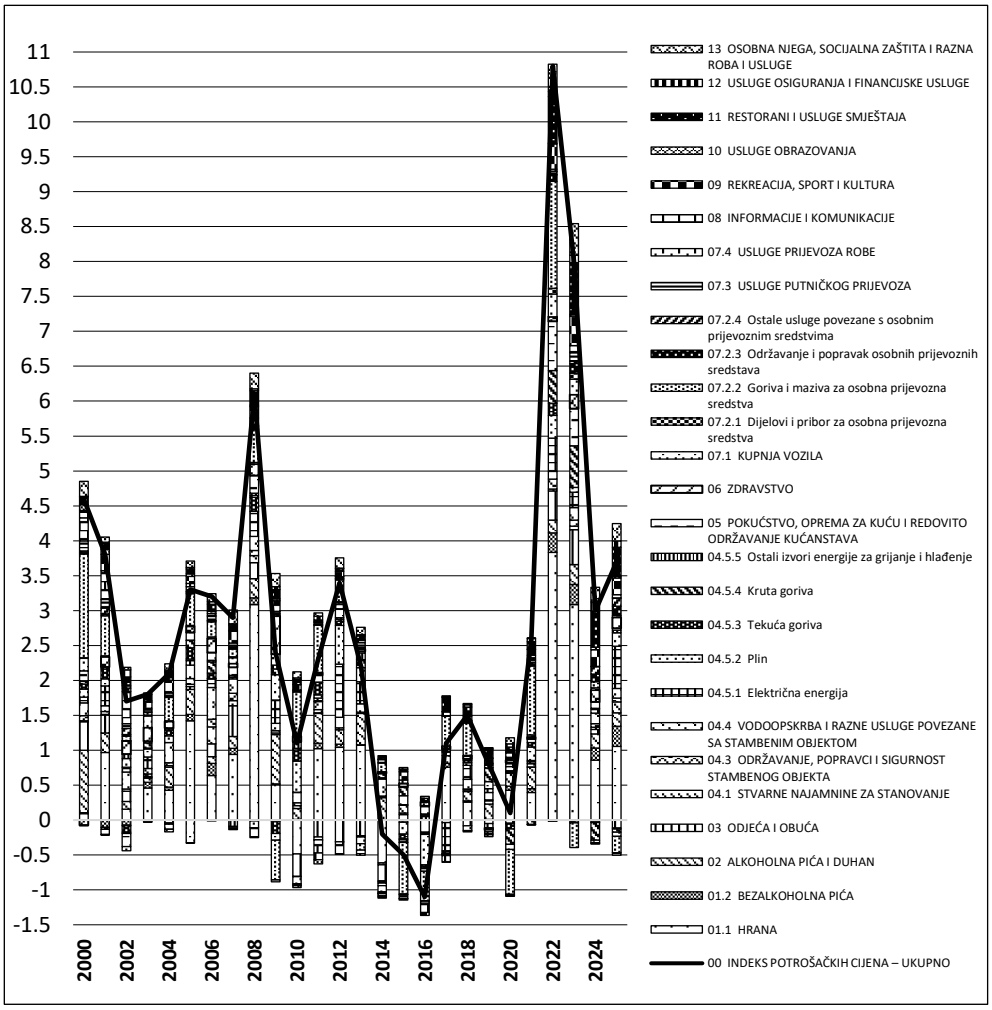


Napomena: Ravna linija prikazuje prosječnu godišnju stopu inflacije.

Izvor: Izračun autora prema podacima DZS-a.

**Slika 21. Dobra i usluge koje su barem jednom bili među pet najvećih generatora ukupne inflacije**

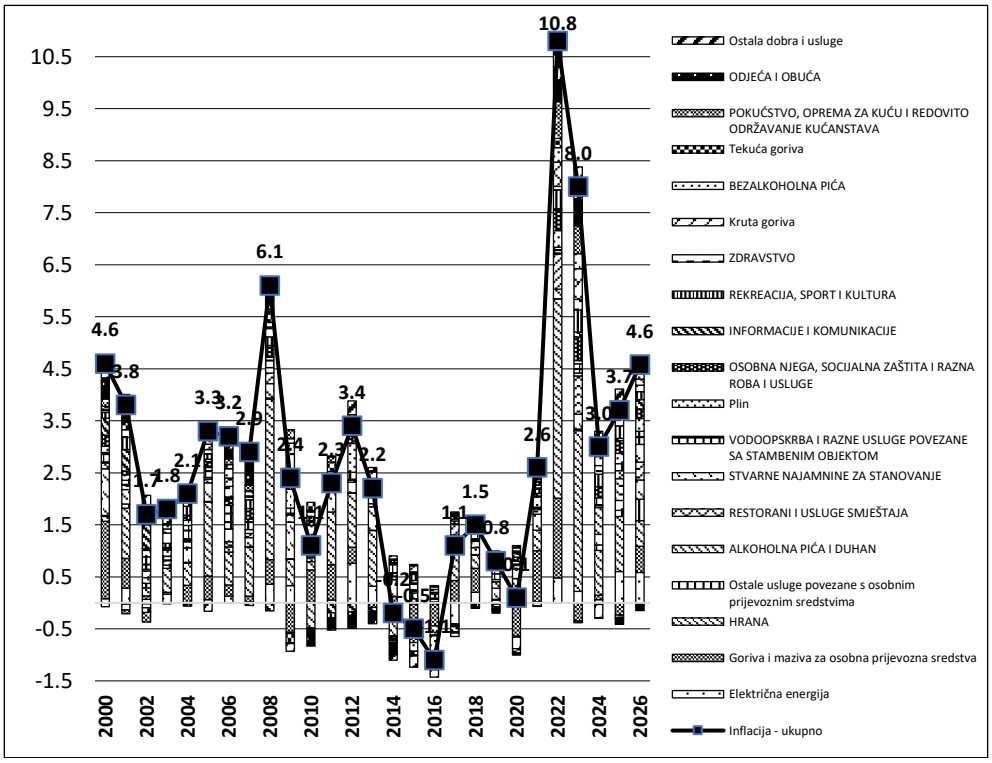


Izvor: Slika 20.

**Slika 22. Prosječna nominalna i realna plaća, sezonski prilagođeni podaci**

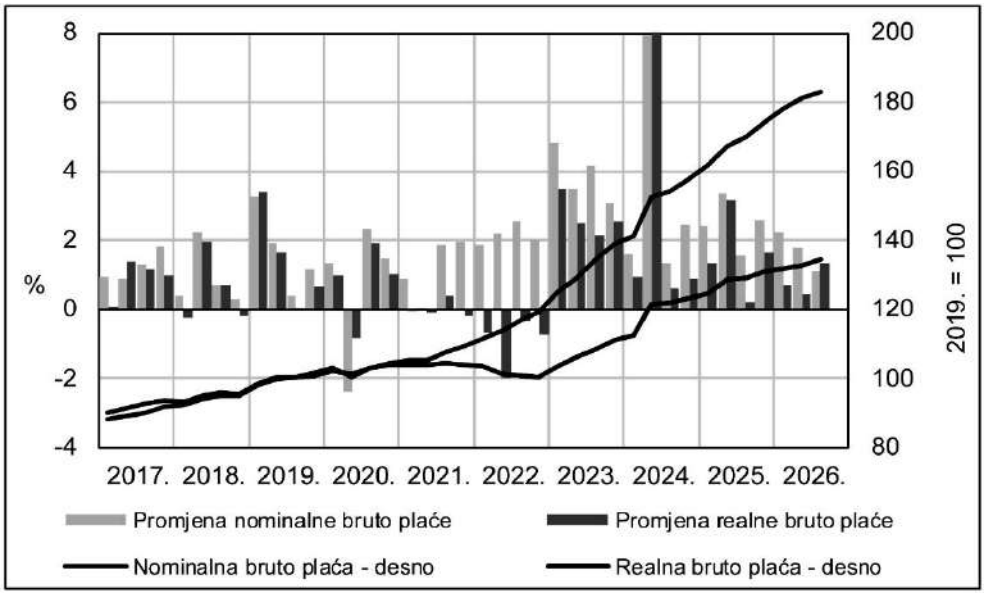


Izvor: HNB, Bilten br. 308 (2026).

# THE EURO IN THE REPUBLIC OF CROATIA AND CITIZENS' PERCEPTION OF ITS EFFECTS

***Abstract***

*The Republic of Croatia adopted the euro on January 1, 2023, thereby becoming a member of the euro area. The aim of this paper was to explain the reasons for adopting the euro by presenting arguments both for and against the move—with a focus on its impact on prices and purchasing power—and to examine citizens' perceptions of this change. To explain the effects on prices and purchasing power, the study utilized statistical data regarding inflation trends, wages, and real purchasing power. The results show that the strongest price growth was during the period of global disruptions, especially during 2022, before the introduction of the euro. Following the currency conversion, inflation gradually declined, while wages grew at a faster rate than in previous years, contributing to a recovery in citizens' purchasing power. Based on the presented data, it can be concluded that the euro was not the primary cause of inflation; rather, it was introduced during a period of pre-existing price pressures. The empirical section of the paper is based on a survey conducted among 158 respondents. The survey results revealed that a large number of citizens associate the euro with rising prices, particularly regarding food, fuel, and services. While the majority of respondents believe that wage growth failed to keep pace with the cost of living, they simultaneously acknowledge certain benefits of the euro, such as currency stability, easier travel, and simplified payments abroad. The paper demonstrates a discrepancy between official economic indicators and the subjective perceptions of citizens.*

***Keywords****: euro, Croatia, inflation, purchasing power, perception of the effects of the euro.*

JEL klasifikacija: H53, I38, D73 i H83

Stručni rad

# SUSTAV PRIVREMENOG UZDRŽAVANJA DJETETA U HRVATSKOJ: INSTITUCIONALNA UČINKOVITOST, FISKALNA ODRŽIVOST I RIZICI

Ivan Madunić*

## SAŽETAK

Sustav privremenog uzdržavanja predstavlja instrument javne intervencije kojim država osigurava kontinuitet uzdržavanja djeteta u situacijama kada roditelj koji ne stanuje s djetetom ne ispunjava svoju zakonsku obvezu uzdržavanja. U Hrvatskoj je od 1. siječnja 2025. godine uspostavljen novi normativni i institucionalni okvir stupanjem na snagu Zakona o privremenom uzdržavanju (Narodne novine, 145/2024), (ZPU), kojim je prestao važiti prethodni Zakon o privremenom uzdržavanju iz 2014. godine, a provedba prava povjerena je Agenciji za osiguranje radničkih tražbina (AORT). Novi model istodobno proširuje razinu zaštite djeteta i povećava potencijalnu fiskalnu izloženost države, osobito zbog novog načina određivanja visine naknade, mogućeg duljeg trajanja prava i obveze države da od obveznika regresno naplati isplaćena sredstva.

Cilj rada jest analizirati institucionalnu učinkovitost, fiskalnu dinamiku i osnovne fiskalne rizike sustava privremenog uzdržavanja u Hrvatskoj u

* Ivan Madunić, ravnatelj Agencije za osiguranje radničkih tražbina (AORT) (e-mail: ivan.madunic@aort.hr).

početnom razdoblju provedbe novog ZPU-a. Analiza se temelji na teorijskim postavkama nove institucionalne ekonomije (transakcijski troškovi, odnos principal-agent…), teorije javnog izbora i ekonomike socijalne države te na deskriptivnoj analizi administrativnih podataka za 2025. i prvih sedam mjeseci 2026. godine. Posebna se pozornost posvećuje razlikovanju početnog portfelja korisnika preuzetog od Hrvatskog zavoda za socijalni rad (HZSR) od novih korisnika, kretanju broja djece obuhvaćene isplatama, visini isplaćenih sredstava, povezanosti iznosa naknade s prosječnom plaćom te regresnoj naplati od obveznika uzdržavanja.

Rezultati pokazuju snažan rast fiskalnog obuhvata sustava nakon njegova institucionalnog preuzimanja. U razdoblju veljača – prosinac 2025. isplaćeno je ukupno 4,06 milijuna eura, dok je u prvih sedam mjeseci 2026. godine isplaćeno približno 4,60 milijuna eura. Istodobno se broj djece obuhvaćene mjesečnim isplatama povećao. Tijekom 2026. godine broj aktivnih korisnika stabilizirao se na oko 5.500. Posebno je značajna činjenica da je početkom 2025. godine od HZSR-a preuzeto približno 1.300 postojećih korisnika, čija je prosječna isplata iznosila oko 90 eura, pa se dinamika ukupnog broja isplata ne može interpretirati isključivo kao rezultat novih zahtjeva.

Rad pokazuje da fiskalna održivost sustava nije određena samo visinom bruto javnih izdataka. Osnovna odrednica dugoročnog fiskalnog učinka jest uspješnost regresne naplate od obveznika uzdržavanja. U početnom razdoblju ukupna potraživanja približno odgovaraju ukupnim isplatama. Značajniji povrat, zbog proceduralnih razloga, još nije ostvaren. Stoga se sustav trenutačno nalazi u fazi visoke bruto fiskalne izloženosti, čiji će stvarni neto fiskalni učinak biti moguće ocijeniti tek nakon operacionalizacije učinkovitih mehanizama naplate.

**Ključne riječi:** privremeno uzdržavanje, socijalna zaštita, institucionalna učinkovitost, fiskalna održivost, fiskalni rizik, regresna naplata, javne financije.

## 1. UVOD

Obveza uzdržavanja djeteta primarno predstavlja privatnopravnu obvezu roditelja, ali njezino neizvršavanje proizvodi posljedice koje nadilaze odnos između roditelja i djeteta. Neplaćanje uzdržavanja može ugroziti materijalnu sigurnost djeteta, povećati rizik siromaštva kućanstva s jednim roditeljem te povećati potrebu za drugim oblicima javne intervencije. U tom se smislu

sustav privremenog uzdržavanja nalazi na sjecištu obiteljskog prava, socijalne politike i javnih financija.

Država u ovom području preuzima specifičnu ulogu. Ona ne preuzima konačnu obvezu roditelja za uzdržavanje djeteta, *nego osigurava privremeni novčani tok prema djetetu*, a potom stupa u pravni položaj djeteta i potražuje isplaćena sredstva od obveznika. Hrvatski model stoga istodobno ima karakter socijalnog transfera i mehanizma javne intervencije u izvršenje privatne obveze uzdržavanja.

Od 1. siječnja 2025. godine ovaj je sustav doživio značajnu transformaciju. Stupanjem na snagu novog Zakona o privremenom uzdržavanju (ZPU) prestao je važiti prethodni ZPU iz 2014. godine. Novi ZPU ne predstavlja samo promjenu nadležnog tijela, već uvodi novi model ostvarivanja prava, određivanja visine privremenog uzdržavanja, trajanja prava i povrata isplaćenih sredstava. Agencija za osiguranje radničkih tražbina (AORT) preuzela je odlučivanje o pravu kao javnu ovlast, čime je provedba sustava institucionalno odvojena od sustava socijalne skrbi.

Posebnost prijelaznog razdoblja jest činjenica da AORT nije započeo provedbu sustava s nultom bazom korisnika. Od Hrvatskog zavoda za socijalni rad preuzeta je isplata za približno 1.300 djece koja su već ostvarivala pravo, pri čemu je prosječni iznos isplate iznosio približno 90 eura mjesečno. Istodobno je započela primjena novih pravila na nove korisnike, što otežava jednostavnu interpretaciju promjena broja djece i fiskalnih izdataka. Sukladno ZPU, AORT je do kraja 2025. godine imao obvezu preispitati prava postojećih korisnika i donijeti novo rješenje s utvrđenim iznosima.

Cilj ovog rada jest stoga analizirati kako je novi normativni okvir utjecao na institucionalnu i fiskalnu dinamiku sustava te identificirati ključne izvore fiskalnog rizika. Posebna se pažnja posvećuje odnosu između broja korisnika, visine naknade, trajanja prava i regresne naplate.

Temeljna istraživačka pretpostavka rada jest da fiskalna održivost sustava privremenog uzdržavanja nije funkcija samo visine javnih izdataka nego rezultanta četiriju međusobno povezanih čimbenika: broja korisnika, visine pojedinačne naknade, trajanja prava i uspješnosti naplate od obveznika.

# 2. SUSTAV PRIVREMENOG UZDRŽAVANJA KAO INSTRUMENT SOCIJALNE ZAŠTITE

## 2.1. Ekonomska funkcija uzdržavanja djeteta

Uzdržavanje djeteta predstavlja ekonomsku obvezu roditelja koja proizlazi iz činjenice da dijete zbog svoje dobi i položaja u pravilu nema vlastitu ekonomsku sposobnost osiguravanja sredstava potrebnih za život. U ekonomskom smislu riječ je o međugeneracijskom transferu unutar obitelji, pri čemu se trošak podizanja djeteta raspoređuje između roditelja.

Problem nastaje kada, po razvodu braka, jedan od roditelja ne izvršava svoju obvezu. Tada se privatni mehanizam uzdržavanja prekida, a posljedice padaju na dijete i roditelja s kojim dijete živi. Ako javna politika ne osigura alternativni mehanizam, materijalni rizik neplaćanja u konačnici može biti socijaliziran kroz druge sustave javne potpore.

Upravo zbog toga sustavi javnog osiguranja ili predujma uzdržavanja postoje u različitim europskim državama. Njihova osnovna funkcija nije oslobađanje roditelja od obveze, nego osiguravanje kontinuiteta prava djeteta u slučaju neizvršavanja obveze, odnosno osiguravanje socijalnog minimuma za dijete.

Hrvatski model slijedi upravo takvu logiku. Zakon privremeno uzdržavanje definira kao novčano primanje koje koristi dijete radi potpore uzdržavanju, dok država nakon isplate preuzima potraživanje prema obvezniku.

Time se uspostavlja dvostruki odnos: *dijete – država*, u kojem država osigurava isplatu, te *država – obveznik uzdržavanja*, u kojem država nastoji vratiti sredstva koja je prethodno isplatila.

Ta dva odnosa potrebno je promatrati odvojeno. Prvi je usmjeren prema socijalnoj zaštiti djeteta, a drugi prema zaštiti javnih financija.

## 2.2. Državna intervencija i socijalna zaštita

Intervencija države u sustav uzdržavanja može se promatrati kroz ekonomiku socijalne države. Osnovna ekonomska funkcija socijalne zaštite jest smanjenje posljedica rizika koje pojedinci ne mogu učinkovito sami osigurati ili ih tržišni i privatni mehanizmi ne uspijevaju odgovarajuće pokriti (Šućur, 2016).

Neplaćanje uzdržavanja predstavlja specifičan rizik jer se posljedice ponašanja jedne osobe prelijevaju na drugu osobu koja nema mogućnost izbora niti kontrole nad ponašanjem obveznika. Dijete nije sudionik ugovornog odnosa u ekonomskom smislu, ali snosi posljedice njegova neizvršavanja.

Stoga je javna intervencija opravdana prije svega iz perspektive zaštite djeteta, a ne zaštite neodgovornog obveznika.

Istodobno, ekonomska teorija socijalne države upozorava na problem moralnog hazarda (Puljiz, 2000; Barr, 2020). Kada država preuzima dio rizika koji bi inače snosio pojedinac, mijenjaju se njegovi poticaji. OECD u raspravama o socijalnom osiguranju naglašava da osiguravanje od rizika može imati pozitivne učinke na ekonomsku sigurnost, ali da istodobno treba voditi računa o mogućim nepovoljnim poticajima i moralnom hazardu (OECD, 2018).

U sustavu privremenog uzdržavanja moralni hazard može se pojaviti na više razina. Najvažniji potencijalni problem odnosi se na obveznika koji bi mogao smanjiti vlastiti napor u izvršavanju obveze ako očekuje da će država osigurati sredstva djetetu. Međutim, taj se rizik smanjuje ako država učinkovito provodi regresnu naplatu.

Zbog toga se socijalna funkcija sustava i fiskalna funkcija naplate ne mogu promatrati kao međusobno suprotstavljene. Naprotiv, učinkovita naplata omogućuje da država istodobno osigura dijete i zadrži snažan poticaj obvezniku da izvršava vlastitu obvezu.

## 2.3. Promjena sustava od 1. siječnja 2025.

Novi Zakon o privremenom uzdržavanju donesen je u prosincu 2024., a stupio je na snagu 1. siječnja 2025. Istoga dana prestao je važiti prethodni Zakon o privremenom uzdržavanju iz 2014. godine.

Novi ZPU donio je promjenu u više područja primjene.

Kao ključna promjena, izmijenjena je institucija nadležna za ostvarivanje prava. O njemu u prvom stupnju sada odlučuje AORT kao javnopravno tijelo koje tu zadaću obavlja u sklopu javne ovlasti.

Značajne novosti donose i izmijenjena materijalna pravila. Prema novom ZPU-u, privremeno uzdržavanje određuje se u visini zakonskog minimuma

uzdržavanja, s time da ne može prelaziti iznos određen ovršnom ispravom. U ovom kontekstu, ovršna isprava podrazumijeva sudsku presudu o razvodu braka ili sudsko rješenje kojim je utvrđena obveza uzdržavanja za roditelja koji ne živi s djetetom. U situacijama kada obveznik ipak podmiruje dio obveze, država preuzima isplatu razlike do zakonskog minimuma.

Ujedno je znatno unaprijeđena i dostupnost samog prava. Dijete ga ostvaruje ako obveznik uzdržavanja ne ispunjava svoju obvezu u cijelosti ili djelomično dulje od mjesec dana od trenutka izvršnosti isprave. Budući da je postupak proglašen žurnim, Agencija je dužna donijeti rješenje najkasnije u roku od 30 dana od zaprimanja urednog zahtjeva ili pokretanja postupka po službenoj dužnosti.

Naposljetku, proširena je i vremenska dimenzija prava. Ono djetetu pripada do navršene 18. godine života, a nakon punoljetnosti nastavlja se pod uvjetima koji općenito vrijede za uzdržavanje punoljetne djece (Narodne novine, 116/2003). To, uz zakonom propisane uvjete, uključuje redovito školovanje do 26. godine života, dok za dijete koje zbog teške i trajne bolesti ili invaliditeta nije sposobno za rad, pravo može trajati sve dok ta nesposobnost postoji.

Navedene promjene znače da novi sustav nije moguće promatrati samo kao administrativni prijenos odgovornosti s jedne institucije na drugu. Radi se o novom socio-ekonomskom pristupu javnoj intervenciji.

## 2.4. Novi model visine i trajanja prava

Visina privremenog uzdržavanja određena je vezano uz zakonski minimum uzdržavanja. Ministar nadležan za socijalnu skrb najmanje jednom godišnje određuje minimalne novčane iznose potrebne za mjesečno uzdržavanje djeteta.

Prema Odluci iz 2025. godine (Narodne novine, 75/2025), koja se temeljila na prosječnoj neto plaći od 1.318 eura za 2024. godinu, minimalni iznosi iznosili su 224 eura za djecu do šest godina, 264 eura za djecu od sedam do dvanaest godina te 290 eura za djecu od trinaest do osamnaest godina.

Nova Odluka iz 2026. godine (Narodne novine, 66/2026), koja se temelji na prosječnoj neto plaći od 1.449 eura za 2025., povećala je iznose na 246, 290 odnosno 319 eura.

**Tablica 1. Novčani iznosi za mjesečno uzdržavanje djeteta**

| Dob djeteta | 2025. | 2026. | Povećanje |
|---|---|---|---|
| do 6 godina | 224 € | 246 € | +22 € |
| 7–12 godina | 264 € | 290 € | +26 € |
| 13–18 godina | 290 € | 319 € | +29 € |

Izvor: autor prema dostupnim podacima.

Ovaj podatak pokazuje da rast prosječne isplate nije moguće interpretirati samo kao posljedicu većeg broja korisnika. Dio povećanja proizlazi iz samog normativnog mehanizma kojim se minimalni iznos uzdržavanja veže uz prosječnu neto plaću.

Odluka iz 2026. godine određuje iznose kao 17 %, 20 % i 22 % prosječne neto plaće, ovisno o dobnoj skupini. Utvrđivanje postotka iznosa temelji se na Obiteljskom zakonu.

Ovakvim je rješenjem uspostavljen izravan mehanizam preko kojeg makroekonomska kretanja automatski utječu na javne rashode.

S jedne strane, taj se utjecaj očituje u činjenici da rast prosječne plaće povlači za sobom povećanje zakonskog minimuma, što posljedično podiže iznose naknada i u konačnici uvećava bruto fiskalne izdatke.

S druge strane, međutim, djeluje suprotan ekonomski kanal. Porast plaća u gospodarstvu ujedno implicira i veću financijsku moć samih obveznika uzdržavanja. To povećava vjerojatnost da će oni uredno podmirivati svoje obveze, čime se državi otvara veći prostor za uspješnu regresnu naplatu isplaćenih sredstava.

# 3. INSTITUCIONALNA UČINKOVITOST SUSTAVA

## 3.1. Uloga Agencije za osiguranje radničkih tražbina

U novom sustavu AORT ima dvojaku funkciju. S jedne strane odlučuje o pravu djeteta i osigurava isplatu. S druge strane utvrđuje obvezu povrata isplaćenih sredstava i pokreće postupke radi njihove naplate.

ZPU izrijekom propisuje da Republika Hrvatska isplatom privremenog uzdržavanja stupa u pravni položaj djeteta te da na državu prelaze tražbine uzdržavanja u visini isplaćenog iznosa.

To znači da je institucionalnu učinkovitost sustava moguće procjenjivati kroz najmanje dvije dimenzije: (1) učinkovitost ostvarivanja prava djeteta, i (2) učinkovitost zaštite javnih financija putem povrata isplaćenih sredstava.

Prva dimenzija zahtijeva brz, jednostavan i pouzdan postupak. Druga zahtijeva učinkovitu identifikaciju obveznika, dostupnost podataka, povezivanje registara i učinkovite mehanizme ovrhe.

## 3.2. Organizacija i administrativni kapacitet

Novi sustav zahtijeva koordinaciju više institucija i informacijskih izvora. Zakon predviđa razmjenu podataka između AORT-a i drugih institucija, uključujući FINA-u (Financijska agencija), HZSR (Hrvatski zavod za socijalni rad) kao i provjeru podataka potrebnih za utvrđivanje prava, iznosa naknade, prestanka prava i povrata sredstava.

U institucionalnoj ekonomiji upravo su takvi procesi važni za razumijevanje transakcijskih troškova. North (2012) institucije definira kao formalna i neformalna pravila koja strukturiraju interakcije, pri čemu njihova kvaliteta utječe na troškove transakcija, informacije i provedbu ugovora.

U sustavu privremenog uzdržavanja transakcijski troškovi nastaju pri: utvrđivanju prava, provjeri podataka, utvrđivanju visine naknade, provjeri uplata obveznika, utvrđivanju prestanka prava, donošenju rješenja o povratu, provođenju ovrhe, praćenju naplate i sl.

Što su ti procesi više automatizirani, standardizirani i međusobno povezani, to je manji administrativni trošak po predmetu.

Prema podacima Agencije (AORT, 2026), na predmetima privremenog uzdržavanja trenutačno radi 12 zaposlenika. Uz približno 5.500 djece obuhvaćene isplatama, to predstavlja približno 458 djece po zaposleniku. Ako se analizira samo nadležni pravni sektor (9 zaposlenika) u kojemu se kreiraju rješenja sukladno Zakonu o općem upravnom postupku, onda je broj predmeta po jednom zaposleniku značajno veći i iznosi oko 611 djece po jednom zaposlenom. Ovaj pokazatelj nije izravna mjera produktivnosti jer

zaposlenici obavljaju različite vrste poslova, ali ukazuje na značaj administrativnog opterećenja.

Za buduće praćenje učinkovitosti bilo bi stoga korisno sustavno pratiti sljedeće pokazatelje: prosječno vrijeme rješavanja predmeta, broj riješenih predmeta po zaposleniku, udio predmeta riješenih u zakonskom roku, broj žalbi, udio ukinutih ili izmijenjenih rješenja, administrativni trošak po korisniku, prosječno vrijeme od priznanja prava do prve isplate, stopu uspješne naplate potraživanja.

## 3.3. Obrada zahtjeva i donošenje odluka

Jedan od prioritetnih ciljeva novog sustava jest omogućiti djetetu brži pristup sredstvima. Zakon propisuje načelo žurnosti i rok od najviše 30 dana za donošenje rješenja nakon urednog zahtjeva.

Brzina odlučivanja u ovom sustavu ima posebnu ekonomsku vrijednost. Za razliku od mnogih drugih javnih transfera, korisnik nije samo administrativni subjekt nego dijete čije se materijalne potrebe ne mogu odgoditi do završetka dugotrajnog postupka.

Istodobno, ubrzanje postupka ne smije rezultirati smanjenjem točnosti odlučivanja. Zbog toga se institucionalna učinkovitost ne može mjeriti samo brzinom.

Prema podacima Agencije, do 31. kolovoza 2026. godine odbijeno je približno 650 zahtjeva, a zaprimljeno 7146. Udio odbijenih zahtjeva u odnosu na ukupno zaprimljene zahtjeve iznosi 9,09 %.

Odbijanje zahtjeva samo po sebi nije pokazatelj neučinkovitosti. Naprotiv, učinkovita institucija mora istodobno osigurati dostupnost prava osobama koje ispunjavaju zakonske uvjete i spriječiti isplatu osobama koje te uvjete ne ispunjavaju.

## 3.4. Digitalizacija, razmjena podataka i naplata

Sustav privremenog uzdržavanja izrazito je pogodan za automatizaciju jer se velik dio relevantnih informacija nalazi u javnim evidencijama.

Za kvalitetno upravljanje predmetima potrebno je povezivanje podataka o: djetetu, roditelju, OIB-u obveznika, sudskoj odluci o uzdržavanju, izvršenim

uplatama, zaposlenju i prihodima, prometu po računima, ovršnim postupcima, promjenama okolnosti, školovanju punoljetnog djeteta i sl.

Zakon predviđa opsežnu razmjenu podataka i svakodnevnu razmjenu s FINA-om u postupcima isplate i naplate te s Državnom sabirnicom u svrhu prikupljanja i obrade potrebnih podataka iz službenih matica.

Institucionalno promatrano, digitalizacija nije samo pitanje tehničke modernizacije. Ona izravno utječe na transakcijske troškove, brzinu odlučivanja i sposobnost institucije da kontrolira fiskalne rizike.

# 4. FISKALNA DINAMIKA SUSTAVA 2025. – 2026.

## 4.1. Početni portfelj preuzet od Hrvatskog zavoda za socijalni rad

Za interpretaciju podataka za 2025. godinu nužno je uzeti u obzir prijelaz između dvaju sustava.

AORT je početkom 2025. preuzeo isplatu za približno 1.300 djece koja su već ostvarivala pravo na privremeno uzdržavanje prema Zakonu o privremenom uzdržavanju iz 2014. godine. Prosječna isplata po djetetu u tom je trenutku iznosila približno 90 eura.

Početni mjesečni fiskalni teret takvog portfelja može se aproksimirati na:

1.300 × 90 € = 117.000 € mjesečno.

Na godišnjoj razini to bi, uz pretpostavku nepromijenjenog broja korisnika i iznosa, odgovaralo iznosu od približno 1.404.000 €.

Ovaj izračun nije procjena stvarnoga godišnjeg rashoda jer se broj korisnika i iznos naknade tijekom godine mijenjaju, ali ilustrira veličinu obveze koju je AORT preuzeo već na početku provedbe novog sustava.

Zbog toga broj djece evidentiran u mjesečnim podacima ne treba interpretirati kao broj novopriznatih prava. On predstavlja broj djece za koju je u određenom mjesecu izvršena isplata i uključuje i postojeći portfelj i nove korisnike.

## 4.2. Novi zahtjevi i djeca obuhvaćena isplatama

Tijekom veljače – prosinca 2025. zaprimljeno je ukupno **2.968 novih zahtjeva**.

**Tablica 2. Pregled broja isplata i zaprimljenih zahtjeva u 2025.**

| Mjesec / 2025. | Broj djece obuhvaćenih isplatom | Broj novih zahtjeva |
|---|---|---|
| veljača | 1.100 | 725 |
| ožujak | 1.229 | 458 |
| travanj | 1.250 | 327 |
| svibanj | 1.437 | 229 |
| lipanj | 1.564 | 138 |
| srpanj | 1.827 | 187 |
| kolovoz | 2.136 | 150 |
| rujan | 2.384 | 201 |
| listopad | 2.514 | 206 |
| studeni | 2.860 | 210 |
| prosinac | 3.106 | 137 |

Izvor: AORT.

U prvih osam mjeseci 2026. godine podaci pokazuju nastavak rasta broja djece obuhvaćene isplatama, ali uz izraženije približavanje razini od 4.000 korisnika mjesečno.

**Tablica 3. Pregled broja isplata i zaprimljenih zahtjeva u 2026.**

| Mjesec / 2026. | Broj djece obuhvaćenih isplatom | Broj novih zahtjeva |
|---|---|---|
| siječanj | 3.257 | 236 |
| veljača | 3.357 | 260 |
| ožujak | 3.474 | 198 |
| travanj | 3.931 | 218 |
| svibanj | 3.914 | 198 |
| lipanj | 3.856 | 154 |
| srpanj | 3.990 | 195 |

Izvor: AORT.

Broj djece obuhvaćene isplatama povećan je s 3.106 u prosincu 2025. na 3.990 u srpnju 2026., odnosno za približno 28,5 %. Kada se analizira isplata

za djecu s različitim OIB-om, u promatranom razdoblju isplaćene su naknade za oko 5500 različite djece (korisnika)[1].

Važno je, međutim, naglasiti da se taj pokazatelj ne može izravno izjednačiti s brojem novih korisnika jer u njemu istodobno sudjeluju početni portfelj, nova prava i prestanci postojećih prava.

## 4.3. Kretanje visine naknade

Ukupne mjesečne isplate tijekom 2025. godine pokazale su snažan rast. U veljači 2025. isplaćeno je 105.856,23 €, dok je u prosincu isplaćeno 617.434,60 €. Ukupno je od veljače do prosinca 2025. isplaćeno 4.056.042,12 €. U prvih sedam mjeseci 2026. isplaćeno je 4.598.385,00 €.

Dakle, u samo prvih sedam mjeseci 2026. isplaćeno je približno 13,4 % više nego tijekom cijele 2025. godine.

**Tablica 4. Pregled isplata po mjesecima i godinama**

| Pokazatelj | 2025. | I. – VII. 2026. |
|---|---|---|
| Ukupne isplate | 4.056.042 € | 4.598.385 € |
| Prosječno mjesečno | 368.731 € | 656.912 € |
| Broj djece na kraju promatranog razdoblja | 3.106 | 3.990 |

Izvor: AORT – Godišnje izvješće o radu za 2025. godinu.

Na prvi pogled rast rashoda može izgledati izrazito visok. Međutim, potrebno ga je dekomponirati.

Ukupni izdatak sustava može se pojednostavnjeno prikazati:

$$I = N \times A \times T \quad (1)$$

gdje je: I = ukupni izdatak; N = broj djece; A = prosječna mjesečna naknada; T = trajanje prava.

U konkretnom modelu A nije egzogena konstanta. Na njega utječu dob djeteta, zakonski minimum i prosječna neto plaća.

[1] U međuvremenu su pojedina djeca izgubila pravo, a druga ušla u sustav isplate, zato je ovaj broj različit od prosječne mjesečne isplate.

Zbog toga rast rashoda može biti rezultat: povećanja broja djece, povećanja prosječne naknade, duljeg trajanja prava te svakako i kombinacije navedenih čimbenika.

## 4.4. Utjecaj rasta plaća na fiskalne izdatke

Prosječna neto plaća u Hrvatskoj za cijelu 2025. godinu iznosila je 1.449 eura, što je bilo 9,9 % više nego 2024. godine. Realni rast iznosio je 6,0 % (DZS, 2026).

Na toj osnovici Odlukom nadležnog ministra iz 2026. godine određeni su minimalni iznosi uzdržavanja od 246, 290 i 319 eura, ovisno o dobi djeteta (Narodne novine, 66/2026).

Ovdje treba istaknuti da rast plaća nije moguće promatrati isključivo kao izvor fiskalnog rizika. Hrvatska je posljednjih godina ostvarila snažan nominalni i realni rast plaća. Vlada Republike Hrvatske ističe da su mjere ekonomske politike, rast zaposlenosti i ulaganja pridonijeli rastu dohotka, a kao cilj je postavljeno daljnje povećanje prosječne plaće (Vlada RH, 2026).

Podaci Eurostata također pokazuju izrazito snažan rast troškova rada u Hrvatskoj: u 2025. godini satni troškovi rada povećani su 11,6 %, među najvišim stopama u Europskoj uniji (EUROSTAT, 2026).

Za sustav privremenog uzdržavanja rast plaća ima dvojaki učinak.

S jedne strane, rast prosječne plaće povećava osnovicu za utvrđivanje minimalnog iznosa uzdržavanja, što izravno utječe na povećanje iznosa privremenog uzdržavanja i, posljedično, na veće pojedinačne isplate iz sustava.

S druge strane, rast plaća povećava potencijalnu platežnu sposobnost obveznika uzdržavanja, čime se stvaraju pretpostavke za urednije podmirivanje obveze uzdržavanja. Posljedično, veća platežna sposobnost obveznika trebala bi povećati i potencijal za regresnu naplatu sredstava koja je država prethodno isplatila na ime privremenog uzdržavanja.

Zbog toga se rast plaća ne može automatski interpretirati kao negativan fiskalni šok. Njegov konačni učinak ovisi o odnosu između povećanja bruto isplata i povećanja naplate od obveznika.

## 4.5. Trajanje prava i potencijalna dugoročna obveza

Novi Zakon o privremenom uzdržavanju proširuje vremenski horizont prava.

Pravo traje do 18. godine, a nakon toga, pod zakonskim uvjetima, i tijekom razdoblja u kojem punoljetno dijete ima pravo na uzdržavanje. To može uključivati redovito školovanje do 26. godine života djeteta. Za dijete koje zbog teške i trajne bolesti ili invaliditeta nije sposobno za rad pravo može trajati dok takva nesposobnost traje, odnosno doživotno ili ukoliko obveznik plaćanja uzdržavanja ne krene s redovitim mjesečnim uplatama.

Takvo rješenje povećava socijalnu zaštitu, ali istodobno uvodi dugoročnu dimenziju fiskalne obveze. Ako se pravo može nastaviti tijekom duljeg razdoblja, onda trenutni broj korisnika ne daje potpunu informaciju o budućoj fiskalnoj izloženosti.

Potrebno je pratiti dobnu strukturu korisnika, očekivano trajanje prava, broj djece koja ulaze u skupinu punoljetnih korisnika, broj korisnika koji nastavljaju školovanje, broj prestanaka prava te broj slučajeva dugotrajnog prava zbog invalidnosti.

U tom smislu fiskalna izloženost sustava ima obilježje dinamičke obveze.

## 4.6. Ukupne isplate i potraživanja prema obveznicima

Prema podacima AORT-a, ukupna potraživanja prema obveznicima trenutno približno odgovaraju ukupno isplaćenim sredstvima. Na temelju podataka za prvih sedam mjeseci 2026. godine riječ je o približno 4.598.385 € potraživanja.

Ovdje je ključno razlikovati bruto fiskalni izdatak od neto fiskalnog troška. Bruto izdatak predstavlja iznos koji je država stvarno isplatila korisnicima. Neto fiskalni trošak predstavlja iznos koji nakon uspješne regresne naplate konačno ostaje na teret javnih financija.

U početnom razdoblju sustava naplata još nije ostvarila značajan povrat. Stoga trenutačni podaci više govore o fiskalnoj izloženosti nego o konačnom fiskalnom trošku.

U drugoj polovici 2026. godine očekuje se donošenje *Pravilnika o načinu ispunjenja novčane tražbine privremenog uzdržavanja putem javnog rada*, nakon provedenog postupka javnog savjetovanja. Njegovim stupanjem na

snagu stvorit će se institucionalni i provedbeni mehanizmi za učinkovitiju regresnu naplatu potraživanja od obveznika uzdržavanja, što bi se u konačnici trebalo pozitivno odraziti na smanjenje neto fiskalnog troška sustava.

# 5. FISKALNI RIZICI I REGRESNA NAPLATA

## 5.1. Bruto i neto fiskalni trošak

Najveći analitički problem pri procjeni fiskalne održivosti sustava jest poistovjećivanje isplaćenih sredstava s konačnim troškom države. Zakon izrijekom uspostavlja subrogaciju. Nakon isplate Republika Hrvatska stupa u pravni položaj djeteta i na nju prelaze tražbine uzdržavanja u visini isplaćenog iznosa.

Stoga je sustav zamišljen kao model u kojem država osigurava likvidnost djetetu, a zatim ostvaruje povrat od primarnog obveznika.

U teorijskom smislu država preuzima vremenski rizik i dio naplatnog rizika. Ako se potraživanje brzo naplati, neto fiskalni trošak je relativno nizak. Ako se naplata odgađa, država mora dulje financirati potraživanje. Ako se potraživanje nikada ne naplati, bruto izdatak se u značajnoj mjeri pretvara u konačni javni trošak.

## 5.2. Rizik nenaplate

Prema trenutačnim podacima Agencija još nije ostvarila značajniji povrat sredstava kroz prisilnu naplatu. To znači da je u početnoj fazi odnos isplaćeno / naplaćeno trenutačno izrazito nepovoljan.

Pokazatelj naplate može se definirati kao:

$$stopa\ povrata\ =\ naplaćena\ sredstva\ /\ ukupna\ potraživanja\ \times\ 100 \qquad (2)$$

Ovaj pokazatelj treba redovito pratiti.

Međutim, niska stopa povrata u početnom razdoblju ne mora značiti da je sustav dugoročno fiskalno neodrživ. Potrebno je uzeti u obzir vrijeme potrebno za uspostavu postupaka povrata, identifikaciju obveznika i provedbu ovršnih postupaka.

Zakon predviđa da Agencija po službenoj dužnosti pokreće postupak povrata isplaćenih sredstava, utvrđuje tražbinu za šestomjesečno razdoblje ili kraće razdoblje i nalaže obvezniku povrat s kamatama.

## 5.3. Očekivani učinci novih mehanizama naplate

Posebno važan mehanizam predstavlja mogućnost ispunjenja obveze putem javnog rada.

Zakon propisuje da obveznik može iznos vratiti putem javnog rada kada se tražbina prethodno nije uspjela namiriti ovrhom na plaći, drugim stalnim primanjima ili sredstvima na računu.

Takav mehanizam predstavlja inovativan oblik povezivanja socijalne politike, fiskalne naplate i aktivacije obveznika koji nema dovoljna novčana sredstva za izravno podmirenje obveze.

Za konačnu ocjenu njegova učinka potrebno je pratiti broj obveznika upućenih u postupak, broj obveznika koji su prihvatili javni rad, broj sati javnog rada, vrijednost tako namirenih obveza, prosječno vrijeme naplate, udio potraživanja naplaćenih javnim radom te ukupnu stopu povrata.

Ako se navedeni mehanizam pokaže učinkovitim, mogao bi značajno utjecati na smanjenje neto fiskalnog troška sustava.

## 5.4. Scenarijska analiza

Za procjenu buduće fiskalne održivosti može se koristiti jednostavan scenarijski model.

Uz pretpostavku da sustav stabilizira broj korisnika na 7.000 djece, uz prosječnu mjesečnu naknadu od 200 € (A), godišnji bruto izdatak iznosi:

$$7.000 \times A \times 12 = [ukupni\ godišnji\ izdatak]\ € \quad (3)$$

Primjerice, ako bi prosječna mjesečna isplata iznosila 200 eura, godišnji bruto izdatak za 7.000 djece iznosio bi:

$$7.000 \times 200 \times 12 = 16{,}8 \text{ milijuna eura.}$$

Uz stopu povrata od 25 % neto izdatak iznosio bi 12,6 milijuna eura, pri stopi povrata od 50 % smanjio bi se na 8,4 milijuna eura, dok bi pri stopi povrata

od 75 % iznosio 4,2 milijuna eura. U slučaju vrlo visoke stope povrata od 90 %, neto fiskalni izdatak smanjio bi se na svega 1,68 milijuna eura.

Ovaj jednostavan primjer pokazuje koliko je naplata važna za fiskalni rezultat.

## 6. UČINKOVITOST SUSTAVA I FISKALNE IMPLIKACIJE

Rezultati analize potvrđuju da je hrvatski sustav privremenog uzdržavanja od 1. siječnja 2025. godine prošao kroz strukturnu promjenu. Ona nije bila samo administrativna nego je obuhvatila nadležnost, visinu prava, dostupnost prava, trajanje prava i mehanizme povrata.

Prva ključna determinanta analize odnosi se na dinamiku volumena obuhvaćenih korisnika. Evidentirani porast broja djece s približno 1.100 u veljači 2025. godine na 3.990 u srpnju 2026. godine nužno je interpretirati u kontekstu inicijalnog portfelja od oko 1.300 korisnika preuzetih od Hrvatskog zavoda za socijalni rad. Slijedom navedenog, navedeni prirast ne implicira linearno generiranje novih korisnika u tom apsolutnom iznosu, već odražava fluktuacije unutar ukupnog obuhvata u kojemu se simultano preklapaju naslijeđena prava, novopriznata prava te procesi njihova prestanka. Longitudinalni uvid u podatke ukazuje na to da je ukupan broj različitih korisnika koji su ostvarili pravo do konca srpnja 2026. godine iznosio približno 5,5 tisuća djece.

S kretanjem broja korisnika korelira i ekspanzija fiskalnog obuhvata. Ukupni volumeni isplata, koji su u razdoblju od veljače do prosinca 2025. godine iznosili oko 4,06 milijuna eura, zabilježili su rast na 4,60 milijuna eura već u prvih sedam mjeseci 2026. godine, što implicira potrebu za identificiranjem strukturnih uzročnika takve dinamike.

Analiza determinanti visine naknade ukazuje na izostanak diskrecijskog odlučivanja od strane AORT-a. Iznosi su regulatorno utvrđeni zakonskim odredbama i godišnjom odlukom resornog ministra, kojom se visina prava vezuje uz dobnu skupinu djeteta i prosječnu neto plaću. S obzirom na to da je odluka za 2026. godinu korigirala iznose naviše u odnosu na 2025. godinu, snažan trend rasta plaća u Republici Hrvatskoj generirao je automatski transmisijski efekt na rashodovnu stranu sustava. U prilog tomu govore i podaci Državnog zavoda za statistiku, prema kojima je prosječna godišnja neto plaća za 2025. godinu iznosila 1.449 eura, uz nominalnu stopu rasta od 9,9 %.

Značajan čimbenik u projekciji troškova predstavlja i vremenska dimenzija, odnosno trajanje prava. Zakonska mogućnost ekstenzije prava nakon punoljetnosti, primarno kroz sustav redovitog obrazovanja do 26. godine života te prolongaciju prava u slučajevima trajne nesposobnosti za rad uzrokovane teškom bolešću ili invaliditetom, značajno podiže razinu socijalne sigurnosti, no simultano generira potencijalne dugoročne fiskalne obveze. U konačnici, kao najvažniji element održivosti cjelokupnog sustava nameće se pitanje efikasnosti naplate potraživanja.

U trenutku promatranja ukupna potraživanja prema obveznicima približno odgovaraju ukupnim isplatama, dok značajniji povrat još nije ostvaren. Zbog toga se sadašnji fiskalni položaj sustava može opisati kao visoka bruto fiskalna izloženost s neizvjesnim budućim neto troškom.

Ako se u sljedećoj fazi ostvari visoka stopa naplate, sustav će, unatoč rastu bruto izdataka, imati relativno ograničen konačni fiskalni učinak. Ako naplata ostane niska, velik dio bruto izdataka pretvorit će se u trajni javni trošak. U tom smislu institucionalna učinkovitost naplate postaje jednako važna kao učinkovitost priznavanja prava.

## 6.1. Institucionalna učinkovitost kao odrednica fiskalne održivosti

Nalazi su u skladu s osnovnim postavkama nove institucionalne ekonomije. North (2012) naglašava da institucije strukturiraju poticaje i utječu na troškove transakcija i provedbe pravila.

U hrvatskom sustavu privremenog uzdržavanja zakon može biti kvalitetno postavljen, ali konačan rezultat ovisi o sposobnosti institucija da ga provode.

Može se stoga razlikovati: **normativna učinkovitost** – kvaliteta zakonskih pravila, od **operativne učinkovitosti** – sposobnost institucije da ta pravila provede brzo, točno i uz prihvatljiv trošak te konačno **fiskalna učinkovitost** – sposobnost sustava da osigura dijete uz što manji konačni trošak za javne financije.

Ove tri dimenzije nisu nužno istovjetne. Sustav može biti vrlo uspješan u brzoj isplati, ali istodobno imati slabu naplatu. Obrnuto, vrlo agresivna naplata može smanjiti fiskalni trošak, ali ako je administrativno spora i složena, može smanjiti ukupnu učinkovitost sustava.

Optimalan sustav stoga treba postići ravnotežu između zaštite djeteta, brzine odlučivanja, zakonitosti, administrativnih troškova i uspješnosti naplate.

## 6.2. Moralni hazard i odgovornost obveznika

Pitanje moralnog hazarda posebno je važno. Ako obveznik zna da će država osigurati djetetu sredstva neovisno o njegovu ponašanju, može se smanjiti njegov neposredni poticaj za plaćanje. Međutim, hrvatski model formalno nastoji ograničiti taj problem tako da država preuzima potraživanje i pokreće postupak povrata. Time se uspostavlja važan princip da državna intervencija štiti dijete, ali ne oslobađa obveznika njegove obveze.

Država ne subvencionira trajno privatnu obvezu, nego privremeno osigurava njezino izvršenje prema djetetu i zatim pokušava regresno naplatiti iznos od primarnog obveznika. Ako je naplata učinkovita, moralni hazard je ograničen. Ako je naplata slaba, dio privatne obveze može se faktično pretvoriti u javni trošak.

# 7. ZAKLJUČAK

Sustav privremenog uzdržavanja djeteta predstavlja specifičan oblik javne intervencije u kojem se socijalna zaštita djeteta i zaštita javnih financija međusobno preklapaju. Hrvatska je od 1. siječnja 2025. uspostavila novi sustav koji je istodobno proširio dostupnost prava, promijenio način određivanja visine naknade, produžio mogući vremenski obuhvat prava i promijenio institucionalnu nadležnost za provedbu.

Analiza početnog razdoblja provedbe pokazuje snažan rast fiskalnog obuhvata. AORT je preuzeo približno 1.300 postojećih korisnika iz sustava Hrvatskog zavoda za socijalni rad, uz prosječnu isplatu od približno 90 eura, a tijekom 2025. i 2026. godine broj djece obuhvaćene isplatama značajno je povećan. Ukupne isplate dosegnule su približno 4,06 milijuna eura tijekom veljače – prosinca 2025., odnosno približno 4,60 milijuna eura već u prvih sedam mjeseci 2026. godine.

Međutim, navedeni rast ne može se interpretirati samo kao povećanje broja korisnika. Na fiskalnu dinamiku utječu i promjena visine naknade, dobna struktura djece i trajanje prava.

Posebno je značajna povezanost minimalnog iznosa uzdržavanja s prosječnom neto plaćom. Prosječna plaća u Hrvatskoj iznosila je 1.449 eura tijekom 2025. godine, što je predstavljalo nominalni rast od 9,9 % u odnosu na 2024. godinu. Na toj su osnovici za 2026. godinu određeni iznosi od 246, 290 i 319 eura, ovisno o dobnoj skupini djeteta.

Rast plaća stoga predstavlja dvosmjerni fiskalni čimbenik. On povećava potencijalni iznos javne isplate, ali istodobno povećava potencijalnu sposobnost obveznika za izvršavanje vlastite obveze i time potencijalni kapacitet regresne naplate.

U promatranom razdoblju ukupna potraživanja prema obveznicima približno odgovaraju ukupnim isplatama, dok značajniji povrat još nije ostvaren. Stoga trenutačni podaci ukazuju na visoku bruto fiskalnu izloženost, ali još ne omogućuju konačnu ocjenu neto fiskalnog troška.

Upravo će sljedeća faza provedbe sustava biti ključna za njegovu ekonomsku evaluaciju. Nakon pune operacionalizacije mehanizama povrata i prisilne naplate bit će moguće izračunati stvarnu stopu povrata i odgovoriti na pitanje u kojoj se mjeri javna intervencija financijski vraća kroz regresnu naplatu.

Na temelju analize mogu se izdvojiti četiri osnovna izvora fiskalnog rizika: (1) rast broja korisnika, (2) rast iznosa naknade povezan s rastom plaća, (3) dulje moguće trajanje prava te (4) neizvjesnost uspješnosti regresne naplate.

Nasuprot tome, četiri osnovna elementa institucionalne učinkovitosti jesu: (1) brzina i točnost odlučivanja, (2) kvaliteta i dostupnost podataka, (3) automatizacija i digitalizacija procesa te (4) učinkovitost povrata isplaćenih sredstava.

Dugoročna održivost sustava privremenog uzdržavanja manifestira se kao izravan rezultat sinergije između socijalnih ciljeva i fiskalne discipline. U tom kontekstu, stabilnost sustava počiva na tri ključna stupa: osiguranju primarne socijalne zaštite djeteta, učinkovitoj institucionalnoj provedbi definiranih mjera te, naposljetku, visokom stupnju uspješnosti u regresnoj naplati potraživanja.

Ako izostane učinkovita naplata, povećanje razine zaštite djeteta može se postupno pretvoriti u trajno povećanje javnog fiskalnog opterećenja. Ako je, međutim, naplata učinkovita, država može ostvariti cilj zaštite djeteta bez proporcionalnog povećanja konačnog fiskalnog troška.

U tom smislu, buduća evaluacija sustava trebala bi napustiti jednostranu perspektivu pukog praćenja rashodovne strane proračuna. Fokus evaluacijskih procesa potrebno je usmjeriti prema relaciji između isplaćenih sredstava i ostvarenog povrata, troškova same institucionalne provedbe te, u konačnici, razine učinkovitosti u zaštiti prava djeteta. Takva analitička paradigma postavlja temelj za razvoj integriranog modela pokazatelja. Taj bi model pratio institucionalnu i fiskalnu učinkovitost kroz sinergiju kvantitativnih parametara, primarno analizirajući dinamiku broja korisnika i novih zahtjeva, stopu priznavanja prava, operativnu brzinu rješavanja predmeta te prosječne iznose naknada i ukupne isplate. Paralelno s time, ključnu dimenziju održivosti činila bi evaluacija ukupnih potraživanja, naplaćenih sredstava i stope povrata, uz precizno utvrđivanje administrativnog troška po korisniku te neto fiskalnog troška za proračun.

Provedbom ovakvoga analitičkog okvira, sustav privremenog uzdržavanja prestaje se promatrati isključivo kao izolirani instrument socijalne politike te postaje integrirani javnopolitički mehanizam čija se uspješnost simultano i višedimenzionalno vrednuje kroz socijalne, institucionalne i fiskalne kriterije.

# LITERATURA

AORT. (15. svibnja 2026). *Agencija za osiguranje radničkih tražbina*. Dohvaćeno iz Godišnji izvještaj o radu za 2025. godinu: https://aort.hr/media/rfpefc34/godi%C5%A1nje-izvje%C5%A1%C4%87e-o-radu-agencije-za-2025-godinu.pdf

Barr, N. (2020). *The Economics of the Welfare State.* Oxford: Oxford University Press.

DZS. (20. veljače 2026). *Državni zavod za statistiku*. Preuzeto 31. kolovoza 2026. iz Plaće: https://podaci.dzs.hr/hr/podaci/trziste-rada/place/

EUROSTAT. (16. lipnja 2026). *Eurostat*. Preuzeto 31. kolovoza 2026. iz Annual increase in labour costs at 3.2% in euro area: https://ec.europa.eu/eurostat/web/products-euro-indicators/w/3-16062026-bp

Narodne novine, 116/2003. (n.d.). *Narodne novine.* Preuzeto 28. kolovoza 2026. iz Obiteljski zakon: https://narodne-novine.nn.hr/clanci/sluzbeni/2003_07_116_1583.html

Narodne novine, 145/2024. (n.d.). *Narodne novine*. Dohvaćeno iz Zakon o privremenom uzdržavanju: https://narodne-novine.nn.hr/clanci/sluzbeni/2024_12_145_2368.html

Narodne novine, 66/2026. (n.d.). *Narodne novine.* Preuzeto 28. kolovoza 2026. iz Odluku o minimalnim novčanim iznosima potrebnim za mjesečno uzdržavanje djeteta: https://narodne-novine.nn.hr/clanci/sluzbeni/full/2026_06_66_803.html

Narodne novine, 75/2025. (n.d.). *Narodne novine.* Dohvaćeno iz Odluku o minimalnim novčanim iznosima potrebnim za mjesečno uzdržavanje djeteta: https://narodne-novine.nn.hr/clanci/sluzbeni/2025_05_75_981.html

North, D. (5. srpnja 2012). Institutions, Institutional Change and Economic Performance. *Cambridge University Press*. Preuzeto 28. kolovoza 2026. iz https://doi.org/10.1017/CBO9780511808678

OECD. (4. prosinca 2018). *OECD.* Preuzeto 28. kolovoza 2026. iz Good Jobs for All in a Changing World of Work: https://www.oecd.org/en/publications/good-jobs-for-all-in-a-changing-world-of-work_9789264308817-en/full-report/component-13.html

Puljiz, V. (rujan 2000). Socijalna država, decentralizacija, socijalna pomoć. *Hrvatska javna uprava*(2), str. 189-222.

Šućur, Z. (1 2016). Uloga i izdaci socijalne zaštite u gospodarskoj krizi. *Revija za socijalnu politiku*(23), str. 7-38. doi: 10.3935/rsp.v23i1.1293

Vlada RH. (25. svibnja 2026). *Vlada Republike Hrvatske*. Preuzeto 2. rujna 2026. iz Prosječna plaća dosegnula je 1.555 eura, a medijalna 1.317 eura: https://vlada.gov.hr/prosjecna-placa-dosegnula-je-1-555-eura-a-medijalna-1-317-eura/46744

# THE TEMPORARY CHILD MAINTENANCE SYSTEM IN CROATIA: INSTITUTIONAL EFFICIENCY, FISCAL SUSTAINABILITY AND RISKS

***Abstract***

*The temporary child maintenance system constitutes an instrument of public intervention through which the state ensures continuity of child maintenance in situations where the parent not residing with the child fails to fulfil their statutory maintenance obligation. In Croatia, a new normative and institutional framework was established on 1 January 2025 with the entry into force of the Temporary Maintenance Act (Official Gazette, 145/2024) (hereinafter: the TMA), which superseded the previous Temporary Maintenance Act of 2014, with implementation of the right entrusted to the Agency for the Protection of Workers' Rights. The new model simultaneously broadens the level of protection afforded to the child and increases the state's potential fiscal exposure, owing in particular to the new method of determining the amount of the benefit, the possibly longer duration of entitlement, and the state's obligation to recover disbursed funds from liable parties by way of recourse.*

*The aim of this paper is to analyse the institutional efficiency, fiscal dynamics, and principal fiscal risks of the temporary maintenance system in Croatia during the initial period of implementation of the new TMA. The analysis draws on the theoretical premises of new institutional economics (transaction costs, the principal-agent relationship, etc.), public choice theory, and welfare state economics, and is grounded in a descriptive analysis of administrative data for 2025 and the first seven months of 2026. Particular attention is devoted to distinguishing the initial portfolio of beneficiaries inherited from the Croatian Institute for Social Work from newly admitted beneficiaries, to trends in the number of children covered by disbursements, to the amounts of funds disbursed, to the relationship between benefit amount and average wage, and to recourse recovery from maintenance-liable parties.*

*The results reveal marked growth in the fiscal scope of the system following its institutional takeover. In the period from February to December 2025, a total of €4.06 million was disbursed, while approximately €4.60 million was disbursed in the first seven months of 2026 alone. At the same time, the number of children covered by monthly disbursements increased, with indications of stabilisation at a level of approximately 5,500 children during*

*mid-2026. Of particular significance is the fact that, at the beginning of 2025, approximately 1,300 existing beneficiaries were taken over, whose average disbursement amounted to around €90 — meaning that the dynamics of the total number of disbursements cannot be interpreted solely as a result of new applications.*

*The paper demonstrates that the fiscal sustainability of the system is not determined by the level of gross public expenditure alone. The key determinant of the long-term fiscal effect is the success of recourse recovery from maintenance-liable parties. In the initial period, total claims approximately correspond to total disbursements, while no substantial recovery has yet been achieved. The system therefore currently finds itself in a phase of high gross fiscal exposure, the true net fiscal effect of which can only be properly assessed once effective recovery mechanisms have been operationalised.*

***Keywords:*** *temporary child maintenance, social protection, institutional efficiency, fiscal sustainability, fiscal risk, recourse recovery, public finance, Croatia.*

JEL klasifikacija: G24, L26, O38, H25
Stručni rad

# POTICANJE ULAGANJA POSLOVNIH ANĐELA U HRVATSKOJ: POREZNA ASIMETRIJA, EUROPSKA ISKUSTVA I PRIJEDLOG MJERA JAVNE POLITIKE

Dina Dogan*
Dino Ivan Dogan**

## SAŽETAK

Svrha ovoga rada jest analizirati stanje tržišta anđeoskog kapitala u Hrvatskoj i predložiti okvir javne politike za njegovo poticanje. Rad polazi od činjenice da je vidljivo tržište ulaganja poslovnih anđela u Hrvatskoj među najslabije razvijenima u Europskoj uniji, unatoč rastućem broju poduzetničkih pothvata u ranim fazama razvoja. Metodološki rad kombinira analizu sekundarnih podataka o europskom i hrvatskom tržištu anđeoskog kapitala, komparativnu analizu instrumenata javne politike u odabranim europskim zemljama te

* Dr. sc. Dina Dogan, profesorica stručnog studija, Zagrebačka škola ekonomije i managementa (e-mail: dina.dogan@zsem.hr), korespondirajući autor.

** Dr. sc. Dino Ivan Dogan, izvanredni profesor, Luxembourg School of Business (e-mail: dino.dogan@luxsb.lu).

nalaze novije bihevioralne literature o odlučivanju poslovnih anđela. Rezultati pokazuju da hrvatski porezni sustav uspješan izlazak iz vlasničkih ulaganja tretira povoljno, dok poticaja za sam ulazak u ulaganje nema, pa neravnoteža koja odvraća privatni kapital od najranijih faza ostaje netaknuta, kao i da usporedive male članice Europske unije ciljanim instrumentima ostvaruju višestruko veće volumene ulaganja. Na temelju analize rad predlaže tri skupine mjera: porezne poticaje za ulaganja u inovativne poduzetnike početnike, javno sufinanciranje anđeoskih ulaganja po modelu fondova uparivanja te mjere jačanja anđeoskih mreža i edukacije ulagatelja. Ograničenja rada proizlaze iz nepotpunosti podataka o nevidljivom dijelu tržišta i iz izostanka *ex ante* procjene fiskalnog učinka predloženih mjera. Izvornost rada leži u tome što prvi put povezuje spoznaje o ponašanju poslovnih anđela s dizajnom javne politike za hrvatski kontekst, i to u trenutku otvaranja zakonodavnog okvira.

**Ključne riječi:** poslovni anđeli, financiranje ranih faza, javna politika, porezni poticaji, poduzetnički ekosustav.

## 1. UVODNA RAZMATRANJA

Financiranje poduzetničkih pothvata u najranijim fazama razvoja jedan je od trajnijih problema financiranja poduzetništva. Bankovno je financiranje u toj fazi ograničeno nedostatkom kolaterala i kratkom poslovnom poviješću, dok fondovi rizičnoga kapitala ulaze s većim iznosima i u kasnijim fazama razvoja poduzetničkih pothvata. Prostor između te dvije granice u razvijenim ekosustavima dijelom popunjavaju poslovni anđeli, pojedinci koji ulažu vlastiti kapital te uz novac osiguravaju iskustvo, kontakte i mentorsku podršku (Wetzel, 1983; Mason i Harrison, 2008; Macht i Robinson, 2009; Dogan, 2024). Zbog te se kombinacije financijskoga i nefinancijskog doprinosa takav kapital teško zamjenjuje javnim potporama ili kreditima, što hrvatsko tržište čini osjetljivim na njegov izostanak. Prema podacima Europske mreže poslovnih anđela (EBAN), vidljivi je dio hrvatskoga tržišta u 2024. godini iznosio 0,25 milijuna eura, dok je Estonija, zemlja s približno trećinom hrvatskoga stanovništva, zabilježila 15,8 milijuna eura (EBAN, 2025; Estonian Business Angels Network (EstBAN), 2025; Eurostat, 2025). Razlika među tim iznosima mjeri se u redovima veličine, pa se nameće pitanje odakle ona zapravo dolazi.

Dio odgovora može se tražiti u strukturi poreznog okvira. Kapitalni dobitak ostvaren otuđenjem financijske imovine nakon dvije godine držanja ne oporezuje se, posebna olakšica za sam čin ulaganja u vlasnički kapital mladog poduzeća ne postoji, a kapitalni se gubitak može prebiti isključivo s dobicima ostvarenima u istoj kalendarskoj godini (Zakon o porezu na dohodak, čl. 67.; Porezna uprava, 2026). Sustav time s ulagateljem dijeli gornju stranu ishoda ulaganja, ali ne i donju, a kod ulaganja u kojima velik dio pozicija završava gubitkom uloženog kapitala (Mason i Harrison, 2002) upravo tretman donje strane može biti važan za odluku o ulasku u ulaganje. Usporedive europske zemlje javnu potporu iz tog razloga češće vežu uz ulazak u ulaganje nego uz njegov izlazak, čime se otvara pitanje u kojoj je mjeri takvo rješenje primjenjivo na zemlju bez jednake povijesti poduzetničkih izlazaka.

U radu se stoga razmatra gdje u hrvatskom poreznom i institucionalnom okviru nastaje prepreka ulaganju privatnog kapitala u najranije faze razvoja poduzeća. Posebna se pozornost posvećuje odnosu poreznog tretmana dobitaka i gubitaka, iskustvima europskih zemalja te načinu na koji se spoznaje o ponašanju poslovnih anđela mogu uzeti u obzir pri oblikovanju javnih mjera. Iz toga proizlaze tri međusobno povezana pitanja: (P1) gdje u poreznom okviru nastaje nesavršenost s obzirom na raspodjelu ishoda anđeoskih ulaganja, (P2) kojim je instrumentima usporedive europske zemlje ublažavaju i što im je u dizajnu zajedničko te (P3) kako nalazi o odlučivanju anđela sužavaju izbor instrumenata za hrvatski kontekst. Budući da rad ne provodi empirijsko testiranje na uzorku, ova se pitanja ne postavljaju kao hipoteze u statističkom smislu, nego kao pretpostavke koje se razmatraju kroz analizu pravnog okvira, usporedbu instrumenata i nalaze literature.

Iz tih pitanja slijede tri pretpostavke. Prva (T1) jest da problem hrvatskog okvira nije prije svega u razini oporezivanja kapitalnih dobitaka, nego u asimetriji između tretmana dobitka i gubitka. Prostor za intervenciju stoga se prije nalazi na ulaznoj strani ulaganja i u tretmanu neuspješnih ulaganja nego u dodatnom rasterećenju izlaska iz ulaganja, koji je već porezno oslobođen. Druga pretpostavka (T2) odnosi se na dizajn europskih rješenja: unatoč razlikama u mehanizmima i izdašnosti potpora, porezni poticaji i drugi instrumenti uglavnom vežu se uz sam trenutak ulaganja, uz određeno razdoblje držanja i ograničenje godišnjeg iznosa. Takav dizajn potporu usmjerava prema anđeoskom segmentu i odvaja je od preuzimanja kontrole nad poduzećem. Istodobno, vrijednost anđeoskog ulaganja ne nastaje samo prijenosom kapitala, nego i odnosom ulagatelja i poduzetnika nakon ulaganja.

Treća pretpostavka (T3) zato je da instrument koji dio potpore povezuje s postinvesticijskom uključenošću poslovnog anđela može imati veći učinak od mjere koja potiče isključivo ulaganje kapitala.

Analiza se temelji na deskriptivnom i komparativnom pristupu javnim politikama. Korišteni su podaci o veličini tržišta poslovnih anđela, relevantni porezni i institucionalni izvori te literatura o odlučivanju poslovnih anđela. U prvom se dijelu analize razmatra hrvatski okvir i problem koji proizlazi iz poreznog tretmana ulaganja. Nakon toga uspoređuju se odabrani europski instrumenti, a nalazi se koriste kao podloga za prijedlog mjera primjerenih hrvatskim uvjetima.

Zemlje nisu odabrane slučajnim uzorkom. Odabrani su primjeri u kojima se poslovni anđeli potiču različitim instrumentima, od poreznih olakšica do izravnih potpora i javnog suulaganja, pri čemu su prednost imali slučajevi za koje su dostupni službeni podaci. U analizu su uključeni i kontrastni primjeri, prije svega Estonija i Italija. Estonija je zanimljiva jer je razvila tržište bez posebne olakšice za poslovne anđele, dok talijanski slučaj pokazuje da sama izdašnost poticaja nije dovoljna ako pravila nisu dovoljno stabilna. Sami se instrumenti zatim uspoređuju prema pet obilježja: mehanizmu, stopi, godišnjem limitu, propisanom razdoblju držanja i tretmanu gubitka.

Ovakav pristup ima i jasna ograničenja. Rad ne utvrđuje uzročni doprinos pojedinog instrumenta razvijenosti nacionalnog tržišta niti raspolaže primarnim podacima o motivima hrvatskih ulagatelja. Zaključci se zato izvode iz strukture propisa, dostupnih podataka i komparativnog materijala, bez *ex ante* procjene fiskalnog učinka predloženih mjera.

## 2. POSLOVNI ANĐELI I FINANCIRANJE RANIH FAZA RAZVOJA

Poslovne anđele literatura opisuje kao pojedince koji vlastiti kapital ulažu u nova ili mlada poduzeća (Wetzel, 1983). Za razliku od institucionalnih ulagatelja, ne upravljaju tuđim sredstvima, pa njihova odluka uključuje financijsku procjenu i osobni odnos prema poduzetniku (Van Osnabrugge i Robinson, 2000), a pregled Edelman, Manolove i Brush (2017) potvrđuje da su njihovo ponašanje i kriteriji odlučivanja postali središnje teme toga polja. Ponuda anđeoskoga kapitala pritom nije fiksna jer uspješni poduzetnici koji ostvare izlaz dio bogatstva, znanja i kontakata usmjeravaju prema novim

pothvatima, što Mason i Harrison (2006) opisuju kao poduzetničko recikliranje: razvijeno se tržište samo širi, dok ono bez povijesti izlazaka uglavnom stagnira. Jednako je važna raspodjela prinosa za koju su Mason i Harrison (2002) pokazali da je izrazito asimetrična. Naime, znatan dio ulaganja završava gubitkom, dok pretežit dio prinosa nosi mali broj uspješnih pozicija. Poslovni anđeo pritom ne promatra samo pojedinačno ulaganje nego cijeli portfelj i raspodjelu mogućih ishoda. Budući da velik broj ulaganja završava gubitkom, smanjenje troška neuspjeha može imati veći utjecaj na odluku o ulaganju nego dodatno povećanje prinosa na onaj manji broj ulaganja koja budu uspješna (Mason i Harrison, 2002).

Jednako je važno kako poslovni anđeli donose odluke. Ne oslanjaju se isključivo na formalne financijske kriterije nego i na iskustvo, heuristike i procjenu osobe poduzetnika (Maxwell, Jeffrey i Lévesque, 2011; Van Osnabrugge i Robinson, 2000). Povjerenje ima važnu ulogu (Harrison, Dibben i Mason, 1997; Lefebvre, Certhoux i Radu-Lefebvre, 2022), a Harrison, Mason i Smith (2015) pokazuju da se heuristike razvijaju učenjem iz prethodnih ulaganja. To ima važnu posljedicu za oblikovanje javnih mjera. Ako se dio vrijednosti ulaganja stvara kroz odnos ulagatelja i poduzetnika, onda sama financijska potpora ne mora biti dovoljna. Poticaj koji istodobno podržava dugoročniju uključenost ulagatelja mogao bi imati drukčiji učinak. Ulaganja u sam odnos stvaraju relacijske rente, vrijednost koju dionici ovog procesa ne bi ostvarili neovisno (Dyer i Singh, 1998; De Clercq i Sapienza, 2001), a Dogan (2024) pokazuje da su te rente veće ondje gdje ulagatelj ulaže resurse specifične za odnos, izraženije u kasnijim fazama razvoja pothvata.

# 3. HRVATSKO TRŽIŠTE POSLOVNIH ANĐELA

## 3.1. Veličina i vidljivost tržišta poslovnih anđela u Hrvatskoj

Najcjelovitiji međunarodni izvor podataka o poslovnim anđelima jest godišnji kompendij EBAN-a, čije je izdanje s podacima za 2024. godinu, objavljeno u listopadu 2025., u trenutku pisanja ovoga rada najnovije dostupno. Prema njemu europsko vidljivo tržište poslovnih anđela u 2024. godini iznosilo je približno 1,22 milijarde eura kroz oko 4.600 investicijskih rundi, uz gotovo 48.000 evidentiranih anđela (EBAN, 2025). Hrvatska je evidentirana s oko 70 anđela, pet ulaganja i volumenom od 0,25 milijuna eura, dok je godinu ranije zabilježeno 1,87 milijuna. Pad od približno 87% čini se znatnim, no na tržištu tako malog opsega godišnju promjenu određuju

pojedinačne transakcije i razlike u obuhvatu prijavljivanja. Statistika pritom obuhvaća samo evidentirani dio tržišta, a Mason i Harrison (2008) pokazuju kako ni razvijene zemlje ne raspolažu izvorom koji bi obuhvatio cjelokupnu neformalnu aktivnost.

Normalizacija tih iznosa brojem stanovnika, koji je 1. siječnja 2025. iznosio 3,87 milijuna u Hrvatskoj i 1,37 milijuna u Estoniji (Eurostat, 2025), daje 0,06 eura po stanovniku u Hrvatskoj naspram 11,53 eura u Estoniji. Estonski iznos pritom nije u cijelosti izravno usporediv jer se od 15,8 milijuna eura na izravna anđeoska ulaganja odnosi 3,8 milijuna, na ulaganja putem fondova 11,4 milijuna, a na platforme skupnoga financiranja 0,6 milijuna (EstBAN, 2025). Usporedi li se samo izravna komponenta, razlika po stanovniku iznosi nekoliko desetaka puta, a ne više od sto. Estonska je mreža evidentirala 255 članova, naspram oko 70 u Hrvatskoj. Sami podaci, međutim, nisu dovoljni da bi se razlika pripisala javnim politikama. Oni prije svega pokazuju koliko je hrvatsko tržište manje i slabije vidljivo u odnosu na uspoređena tržišta.

Organizirano anđeosko ulaganje u Hrvatskoj postoji od 2008. godine i osnutka Hrvatske udruge investitora i poslovnih anđela CRANE, čiji su članovi do 2015. godine uložili više od 20 milijuna kuna (CRANE, 2025); podatak je, nažalost, star više od deset godina i ilustrira problem mjerljivosti hrvatskoga tržišta. Tijekom 2025. godine pojavila se druga nacionalna mreža, Croatian Business Angels Network (CBAN, 2025). Veći broj mreža poslovnih anđela može povećati broj ulagatelja, ali broj članova nije pokazatelj razvijenosti tržišta; relevantniji su broj transakcija, iznos uloženoga kapitala i postinvesticijska aktivnost (Mason i Harrison, 2002), koji nisu sustavno dostupni. Infrastruktura za kasnije faze poduzetničkih pothvata znatno je razvijenija, budući da Hrvatska agencija za malo gospodarstvo, inovacije i investicije (HAMAG-BICRO) provodi zajmove, jamstva i bespovratne potpore, Hrvatska banka za obnovu i razvitak (HBOR) kreditne programe, a kroz programe s Europskim investicijskim fondom (EIF) razvijeni su i instrumenti rizičnoga kapitala (EIF, 2026).

## 3.2. Porezna asimetrija kao središnja prepreka efikasnosti tržišta

U Hrvatskoj se kapitalni dobici od financijske imovine ne oporezuju ako je imovina otuđena nakon dvije godine od stjecanja, a u suprotnom se oporezuju po stopi od 12%. Gubitak se može odbiti isključivo od dobitaka ostvarenih u istoj kalendarskoj godini i ne prenosi se u sljedeća razdoblja (Zakon o porezu

na dohodak, čl. 67.; Porezna uprava, 2026). Takav sustav nije formalno diskriminatoran, ali u trenutku donošenja odluke o ulaganju nije neutralan. Dvogodišnje oslobođenje značajno je povoljniji tretman gornje strane ishoda, izdašniji nego u pojedinim zemljama koje anđeoska ulaganja aktivno potiču, dok je problem u Hrvatskoj na donjoj strani. Poslovni anđeo koji izgubi cjelokupan uloženi kapital taj gubitak može iskoristiti samo ako je u istoj godini ostvario kapitalni dobitak, što se kod ulaganja s horizontom od pet do sedam godina i raspodjelom u kojoj većina pozicija ne donosi povrat (Mason i Harrison, 2002) rijetko ostvaruje. Hrvatski porezni sustav tako sudjeluje u uspjehu ulaganja, dok u neuspjehu ne sudjeluje. Upravo ta razlika predstavlja središnji problem analiziranog poreznog tretmana.

Ni drugi instrumenti ne ispunjavaju taj prostor. Zakon o poticanju ulaganja usmjeren je na projekte poduzetnika, a ne na fizičke osobe koje ulažu u tuđa mlada poduzeća, dok Zakon o unapređenju poduzetničke infrastrukture među potpornim institucijama navodi razvojne agencije, inkubatore, akceleratore, parkove i slobodne zone, ali ne i mreže poslovnih anđela, pa one ostaju izvan Jedinstvenog registra i sustava potpora. Pojam poslovnog anđela u hrvatskom pravnom okviru ne postoji kao kategorija, što otežava i dodjelu potpora i praćenje tržišta. Naznake promjena ipak postoje. Godišnji plan rada Ministarstva gospodarstva za 2026. godinu računa s izmjenama Zakona o poticanju razvoja malog gospodarstva, premda poslovne anđele ne spominje (Ministarstvo gospodarstva, 2025), dok Strategija Europske unije za *startupe* i *scaleupe* izrijekom najavljuje potporu poslovnim anđelima i njihovim mrežama tijekom 2026. (European Commission, 2025).

# 4. EUROPSKA ISKUSTVA U POTICANJU POSLOVNIH ANĐELA

## 4.1. Porezni poticaji i izravne potpore

Ujedinjeno Kraljevstvo ima najdugovječniji sustav poticanja anđeoskih ulaganja. Enterprise Investment Scheme (EIS) porezno umanjenje veže uz sam ulazak i, što je za odluku ulagatelja važnije od visine stope, dopušta prebijanje gubitka s poreznom osnovicom ako pothvat propadne (HM Revenue and Customs (HMRC), 2025). Za najranije faze poduzetničkog razvoja 2012. godine uveden je Seed Enterprise Investment Scheme (SEIS), s dvostruko većom stopom i strožim ograničenjima veličine i starosti

korisnika (HMRC, 2026). Njemačka je odabrala drugačiji mehanizam pa tako njihov program INVEST ne počiva na poreznoj olakšici, nego na izravnoj bespovratnoj potpori pri stjecanju udjela, uz potporu pri izlasku u visini 25% dobiti (Bundesamt für Wirtschaft und Ausfuhrkontrolle (BAFA), b. d.). Prednost je neovisnost o visini porezne obveze, budući da odbitak malo vrijedi ulagateljima bez visoke porezne osnovice. Njemački primjer pokazuje i da su izravne potpore izložene fiskalnim rezovima jer je stopa potpore pri stjecanju, povišena 2023. na 25%, naknadno snižena na 15% (BAFA, 2023; BAFA, b. d.). Portugal je 2017. uveo Program Semente, kojim se odbitak veže uz ulaganje u mlada inovativna poduzeća uz uvjet da stečeni udjel ne prelazi 30% kapitala, čime se anđeosko ulaganje razdvaja od preuzimanja kontrole (Estatuto dos benefícios fiscais, čl. 43.º-A; PwC Portugal, 2026).

Talijansko iskustvo pokazuje da izdašna shema nije dovoljna ako regulatorna nestabilnost naruši povjerenje ulagatelja u trajnost pravila tijekom cijeloga ciklusa ulaganja. Italija od 2012. primjenjuje redovni odbitak od 30%, dopunjen za fizičke osobe pojačanim odbitkom u režimu *de minimis* potpore, koji je 2025. povišen na 65% (Decreto-Legge br. 179/2012, čl. 29. i 29-bis; Fiscomania, 2026). Odobrenje Europske komisije za redovni režim isteklo je 31. prosinca 2025., a novo do početka 2026. godine nije ishođeno, pa za nova ulaganja ostaje samo uži odbitak u režimu *de minimis* (We Wealth, 2026). Tablica 1. u nastavku sažima parametre instrumenata prema pet dimenzija navedenih u metodološkom okviru u prvom poglavlju.

**Tablica 1. Odabrani europski instrumenti poticanja anđeoskih ulaganja**

| Zemlja i instrument | Mehanizam | Stopa | Godišnji limit | Držanje | Tretman gubitka |
|---|---|---|---|---|---|
| Ujedinjeno Kraljevstvo, EIS | porezno umanjenje | 30% | 1 mil. GBP (2 mil. za znanjem intenzivna) | 3 god. | prebija se s poreznom osnovicom |
| Ujedinjeno Kraljevstvo, SEIS | porezno umanjenje | 50% | 200.000 GBP | 3 god. | prebija se s poreznom osnovicom |
| Njemačka, INVEST | bespovratna potpora | 15% pri stjecanju, 25% dobiti pri izlasku | 3 mil. EUR po poduzeću godišnje; potpora do 100.000 EUR po ulagatelju | 3 god. | nije vezano uz poreznu obvezu |

| Zemlja i instrument | Mehanizam | Stopa | Godišnji limit | Držanje | Tretman gubitka |
|---|---|---|---|---|---|
| Portugal, Semente | porezni odbitak | 25% | 100.000 EUR (do 40% porezne obveze) | 4 god. | bez posebnog tretmana |
| Italija, redovni režim (do 31. 12. 2025.) | porezni odbitak | 30% | 1 mil. EUR | 3 god. | bez posebnog tretmana |
| Italija, režim *de minimis* | porezni odbitak | 65% | 100.000 EUR | 3 god. | bez posebnog tretmana |

Izvor: izradili autori rada temeljem podataka HM Revenue and Customs (2025, 2026), BAFA (2023, b. d.), PwC Portugal (2026), Fiscomania (2026), We Wealth (2026).

Unatoč razlikama među navedenim shemama, u Tablici 1. uočava se nekoliko zajedničkih elemenata. Poticaj se uglavnom ostvaruje već pri ulaganju, ulagatelj mora zadržati udjel određeno vrijeme, a godišnji limiti ograničavaju opseg ulaganja koji može biti obuhvaćen olakšicom. Razlike su prije svega u načinu provedbe i visini potpore. Za hrvatski slučaj posebno je zanimljiv britanski model jer, za razliku od većine promatranih shema, predviđa i povoljniji tretman gubitka.

## 4.2. Estonija kao primjer dobrog razvoja poslovnih anđela

Estonija je u usporedbu uključena zato što ne potvrđuje pretpostavku T1. Razvijeno tržište nije izgradila oslanjajući se na posebnu poreznu olakšicu, a ipak bilježi volumen koji po stanovniku višestruko premašuje europski prosjek (EstBAN, 2025). Njezina je populacija poslovnih anđela nastala iz nekoliko velikih i vremenski zbijenih poduzetničkih izlazaka koji su stvorili skupinu ljudi s kapitalom, iskustvom i međusobnim povjerenjem, dakle poduzetničko recikliranje u čistom obliku (Mason i Harrison, 2006). To ipak ne znači da bi takav pristup dao isti rezultat u Hrvatskoj, budući da je baza ulagatelja nastalih iz uspješnih izlazaka ovdje znatno uža. Estonsko iskustvo zato ne treba tumačiti kao argument protiv poreznih poticaja. Ono prije pokazuje da poticaj sam po sebi ne može zamijeniti razvijen poduzetnički ekosustav.

## 4.3. Javno suulaganje kao instrument politika

Drugi važan instrument jest javno suulaganje, u kojem javni kapital ne donosi samostalnu odluku, nego ulazi u transakciju zajedno s privatnima. Privatni ulagatelj i dalje mora procijeniti kvalitetu projekta, a sindiciranje može povećati broj ulagatelja (Baldock i Mason, 2015). Britanski Angel CoFund i škotski fond suulaganja najpoznatiji su primjeri, a Europski investicijski fond putem European Angels Fund sklapa dugoročne sporazume s iskusnim anđelima i odluku prepušta njima; njemački je ogranak od 2012. ostvario oko 500 suulaganja (EIF, b. d.). Za razliku od poreznih poticaja, suulaganje javna sredstva veže uz kvalitetu pojedinačne transakcije, a ne uz status ulagatelja. Za Hrvatsku je pritom važna mogućnost oslanjanja na postojeću infrastrukturu HBOR-a i EIF-a, čime bi se instrument uključio u sustav bez osnivanja novih institucija.

# 5. PRIJEDLOG MJERA JAVNE POLITIKE ZA HRVATSKU

Država bi trebala intervenirati ondje gdje postoji identificirana tržišna nesavršenost, ali ne i zamijeniti privatnu procjenu investicijske prilike. Hrvatskoj nije potreban sustav koji bi poslovne anđele licencirao ili ih pretvorio u reguliranu kategoriju ulagatelja, s obzirom na to da bi to podiglo troškove ulaska na tržište na kojem ulagatelja ionako nedostaje. Na temelju prethodne analize predlaže se paket od tri skupine mjera. Prva se odnosi na porezni poticaj vezan uz samu transakciju, druga na javno suulaganje s poslovnim anđelima, a treća na razvoj infrastrukture i baze ulagatelja.

## 5.1. Prvi stup: porezni poticaj za ulaganja u inovativna poduzeća

Prvi se stup mjera odnosi upravo na dio procesa u kojem je utvrđena najveća porezna asimetrija, odnosno na trenutak ulaska u ulaganje. Predlaže se umanjenje obveze poreza na dohodak u visini od 30% izravnog novčanog ulaganja u vlasnički kapital inovativnog poduzeća, odnosno 50% za poduzeća mlađa od tri godine, po uzoru na britansku dvojnu shemu EIS i SEIS. Godišnji bi limit iznosio 150.000 eura po ulagatelju, uz uvjet da stečeni udjel ne prelazi 30% kapitala, čime se poticaj usmjerava prema manjinskom ulaganju, a ne prema preuzimanju poduzetničkih pothvata. Predložene stope i limit ne predstavljaju empirijski utvrđene optimalne vrijednosti. Riječ je o prijedlogu koji je određen usporedbom raspona postojećih europskih rješenja prikazanih

u Tablici 1. Za funkcioniranje sheme ključan je prijenos neiskorištenog dijela olakšice u sljedeće tri porezne godine jer bi bez njega ulaganje od 150.000 eura uz stopu od 50% pretpostavljalo godišnju poreznu obvezu od 75.000 eura, koju ima vrlo uzak krug obveznika. Upravo je to razlog zbog kojeg je Njemačka odabrala bespovratnu potporu.

Drugi je element tretman gubitka, koji je za hrvatsko tržište poslovnih anđela i financiranja poduzetničkih pothvata važniji od visine stope. Ako država preuzima dio rizika već pri ulasku u ulaganje, bilo bi logično omogućiti sličan tretman i u slučaju neuspjeha ulaganja. Za kvalificirana ulaganja zato bi se mogao dopustiti odbitak kapitalnoga gubitka od ukupne porezne osnovice, uz umanjenje za prethodno iskorišteni poticaj i bez ograničenja na istu kalendarsku godinu. Predlaže se i minimalni rok držanja od četiri godine, budući da dulji rok potiče postinvesticijsku uključenost ulagatelja i djeluje u smjeru pretpostavke T3. Definiciju prihvatljivog poduzeća treba uskladiti s pravilima o državnim potporama (Uredba Komisije (EU) br. 651/2014) i osigurati notifikaciju, a talijansko i njemačko iskustvo pokazuju da o trajnosti pravila ovisi djelotvornost sheme. Poticaj valja vezati uz transakciju i karakteristike poduzeća, a ne uz certificiranje ulagatelja, uz jasna pravila protiv ulaganja povezanih osoba.

## 5.2. Drugi stup: fond suulaganja s poslovnim anđelima

Drugi stup mjera predviđa javni fond koji bi, zajedno s poslovnim anđelima, ulagao u kvalificirane transakcije u omjeru do 1:1, uz najmanje tri poslovna anđela po transakciji (Baldock i Mason, 2015). Odluku pritom donose poslovni anđeli, dok ih javni kapital prati, a početna kapitalizacija od 20 do 30 milijuna eura tijekom pet godina bila bi razmjerna veličini hrvatskog tržišta. Javni novac pritom nije fiskalno besplatan, jer povrat ovisi o uspješnosti visokorizičnog portfelja. Ako relacijske rente rastu s ulaganjima specifičnima za odnos, a učinak je najizraženiji u kasnijim fazama razvoja pothvata (Dogan, 2024), fond nije uputno dizajnirati kao jednokratnu potporu ulasku, nego uz rezervaciju za naknadna ulaganja. Zbog toga bi pravo na suulaganje trebalo povezati i s dokazivom postinvesticijskom uključenošću anđela, primjerice kroz mjesto u savjetodavnom tijelu ili mentorsku obvezu, a ne samo s uplatom kapitala. Ukupno bi javno sudjelovanje trebalo ograničiti na najviše 60% vrijednosti transakcije, kako se preklapanjem instrumenata privatni rizik ne bi prekomjerno smanjio.

## 5.3. Treći stup: infrastruktura tržišta i baza poslovnih anđela

U trećem stupu predlaže se nekoliko mjera koje ne zahtijevaju velika javna sredstva. Operativni troškovi anđeoskih mreža mogli bi se ograničeno sufinancirati prema broju posredovanih transakcija, kvaliteti sindiciranja i postinvesticijskoj aktivnosti, a ne prema samom broju članova. Važan dio tog stupa bila bi i edukacija novih anđela usmjerena na analizu slučajeva, mentorstvo iskusnih poslovnih anđela i upravljanje portfeljem, a ne isključivo na financijsko vrednovanje, što proizlazi iz nalaza da se anđeoske heuristike razvijaju učenjem iz prethodnih ulaganja (Maxwell i sur., 2011; Harrison i sur., 2015). Treća je mjera uvrštavanje mreža poslovnih anđela među poduzetničke potporne institucije, čime bi im se otvorio pristup Jedinstvenom registru i sustavu potpora te bi se ublažio problem nedostatka podataka jer bi porezni poticaj vezan uz transakciju ostavio administrativni trag i omogućio prvo sustavno praćenje anđeoskih ulaganja.

## 5.4. Rizici provedbe, fiskalni okvir i evaluacija

Predloženi paket nije bez rizika. Jedan od važnijih je mrtvi teret, odnosno mogućnost da država subvencionira ulaganja koja bi se dogodila i bez poticaja. Rizik se može ograničiti usmjeravanjem sheme na najranije faze ulaganja i vremenskim ograničenjem njezina trajanja (Edelman i sur., 2017). Zlouporaba zahtijeva jasne kriterije prihvatljivosti, isključenje povezanih osoba i naknadnu kontrolu, a nestabilnost politike, koju ilustriraju talijanski i njemački slučaj, unaprijed definirano trajanje sheme i obveznu evaluaciju. Fiskalni trošak zahtijeva zasebnu procjenu. Primjerice, usmjeri li se dvije trećine ulaganja u poduzeća starija od tri godine po stopi od 30%, a jedna trećina ulaganja u najmlađa poduzeća po stopi od 50%, prosječna efektivna stopa iznosi oko 37%. Približi li se hrvatsko tržište u pet godina estonskoj izravnoj anđeoskoj komponenti po stanovniku, dakle iznosu od oko 11 milijuna eura godišnje, približan godišnji porezni rashod bio bi oko 4 milijuna eura; uzme li se ukupan estonski volumen, mjerilo koje se prethodno ocijenilo samo djelomično usporedivim, iznosi rastu na oko 45 i oko 16 milijuna eura. Raspon je ilustrativan i njegov gornji kraj valja čitati kao gornju granicu, pa je prije uvođenja sheme nužna *ex ante* procjena. Takvu je procjenu uputno provesti prije upućivanja izmjena poreznih propisa u proceduru, i to mikrosimulacijom na podacima Porezne uprave o obveznicima poreza na dohodak od kapitala te na podacima anđeoskih mreža o broju i veličini

transakcija, sa scenarijima niske, srednje i visoke prihvaćenosti mjere i horizontom projekcije od pet godina. Prva provjera na stvarnim podacima mogla bi se napraviti nakon tri godine primjene, kada porezne evidencije daju dovoljno opažanja za ponovljenu procjenu mrtvoga tereta.

Uz navedene rizike postoji i ograničenje dokazne osnove. Europske sheme koje ovdje služe kao dobri primjeri uglavnom su opisane deskriptivno, a rigoroznih uzročnih evaluacija je malo, pa se veličina učinka ne može unaprijed tvrditi. Zbog toga podaci iz poreznih evidencija moraju biti upotrebljivi za procjenu mrtvoga tereta. Dodatno, postoji i prigovor samoj dijagnozi: usko grlo moglo bi biti na strani potražnje, a ne ponude kapitala, pa bi olakšica podigla vrednovanja umjesto broja financiranih poduzeća. Protiv toga djelomično govore fondovi rizičnoga kapitala, koji pothvate traže u kasnijim fazama razvoja poduzetničkih pothvata, dok nastanak druge anđeoske mreže u Hrvatskoj ne govori ništa o potražnji jer se tiče samo ponude kapitala. Pitanje stoga ostaje otvoreno i trebalo bi ga provjeriti podacima o pothvatima koji traže rano financiranje, kakvima se danas, prema saznanjima autora, ne raspolaže.

## 6. ZAKLJUČNA RAZMATRANJA

Analiza pokazuje da je hrvatska financijska infrastruktura razvijenija u kasnijim fazama poduzetničkog ciklusa nego na njegovu početku, dok su mogućnosti financiranja najranijih faza i dalje ograničene. U takvom se okruženju kao važan problem pokazuje porezni tretman ulaganja, osobito razlika između tretmana dobitka i gubitka. Nakon dvije godine držanja ulagatelj ne plaća porez na ostvareni kapitalni dobitak, dok je mogućnost priznavanja kapitalnoga gubitka ograničena na istu kalendarsku godinu. Kod ulaganja poslovnih anđela, koja su rizična i za koja se očekuje veći broj neuspješnih ulaganja, takva razlika može utjecati na odluku o ulaganju više nego sama visina porezne stope.

Usporedba odabranih europskih rješenja pokazuje da se poticaji najčešće vežu uz sam trenutak ulaganja, uz određeni rok držanja i ograničenje iznosa ulaganja. Britanski model pritom predstavlja posebno zanimljiv primjer jer, uz porezni poticaj pri ulasku, predviđa i povoljniji tretman gubitka. S druge strane, estonsko iskustvo pokazuje da posebna porezna olakšica nije nužan uvjet razvoja tržišta poslovnih anđela, osobito kada već postoji razvijena poduzetnička baza nastala kroz uspješne izlaske iz ulaganja. Za Hrvatsku je

taj primjer važan upravo zato što upozorava na to da porezni instrument ne može sam nadomjestiti nedostatak kapitala, iskustva i mreža ulagatelja.

Na temelju navedenih nalaza predlaže se kombinacija triju stupova mjera: poreznog poticaja za ulaganje u inovativna poduzeća, javnog fonda suulaganja s poslovnim anđelima te mjera usmjerenih na razvoj tržišne infrastrukture i baze ulagatelja. Porezni bi poticaj trebao smanjiti rizik povezan s ulaskom u ulaganje, ali istodobno treba voditi računa o tretmanu gubitka kako se potpora ne bi odnosila samo na uspješan ishod ulaganja. Javno suulaganje moglo bi pomoći u povećanju broja i veličine transakcija, pri čemu bi odluka o ulaganju trebala ostati na poslovnim anđelima, a javni kapital imati ulogu praćenja privatnog ulaganja. Pritom bi bilo korisno ostaviti prostor za naknadna ulaganja i aktivno sudjelovanje poslovnih anđela u razvoju poduzeća, jer njihova vrijednost za poduzetnika ne završava samom uplatom kapitala. Treći dio predloženog okvira odnosi se na razvoj mreža, edukaciju novih anđela i sustavnije prikupljanje podataka o njihovim ulaganjima. Predloženi parametri poreznog poticaja i fonda ne predstavljaju empirijski utvrđene optimalne vrijednosti, nego prijedlog izveden iz usporedbe postojećih europskih rješenja i obilježja hrvatskog tržišta. Zbog toga bi prije uvođenja mjera trebalo napraviti detaljniju fiskalnu procjenu i provjeriti u kojoj mjeri hrvatskim poduzećima u ranoj fazi doista nedostaje kapital, a u kojoj je problem na strani potražnje za financiranjem.

Ograničenje ovog rada upravo je nedostatak primarnih podataka o motivima hrvatskih poslovnih anđela, kao i činjenica da se ne provodi uzročna procjena učinka predloženih mjera. Daljnje istraživanje trebalo bi zato povezati podatke o anđelima i poduzećima koja traže rano financiranje s podacima Porezne uprave, kako bi se moglo procijeniti bi li predloženi instrumenti doista povećali broj ulaganja ili bi prije svega subvencionirali ulaganja koja bi se dogodila i bez njih.

## LITERATURA

BAFA (b. d.). *INVEST – Zuschuss für Wagniskapital*. Dostupno na https://www.bafa.de/

BAFA (2023). „INVEST – Zuschuss für Wagniskapital“ bis 2026 verlängert und Erwerbszuschuss auf 25 Prozent erhöht. Dostupno na https://www.bafa.de/

Baldock, R. i Mason, C. (2015). Establishing a new UK finance escalator for innovative SMEs: The roles of the Enterprise Capital Funds and Angel Co-Investment Fund. *Venture Capital*, *17*(1-2), 59-86. https://doi.org/10.1080/13691066.2015.1021025

CBAN (2025). Croatian Business Angels Network. Dostupno na https://cban.eu/

CRANE (2025). O nama. Dostupno na https://crane.hr/

De Clercq, D. i Sapienza, H. J. (2001). The creation of relational rents in venture capitalist-entrepreneur dyads. *Venture Capital*, *3*(2), 107-127.

Decreto-Legge br. 179/2012, čl. 29. i 29-bis. Gazzetta Ufficiale, br. 245/2012.

Dogan, D. (2024). *An analysis of business angels' investment behavior and criteria* (doktorska disertacija). Ljubljana: Univerza v Ljubljani, Ekonomska fakulteta.

Dyer, J. H. i Singh, H. (1998). The relational view: Cooperative strategy and sources of interorganizational competitive advantage. *Academy of Management Review, 23(*4), 660-679. https://doi.org/10.5465/amr.1998.1255632

EBAN (2025). EBAN Statistics Compendium: European Early Stage Market Statistics 2024. Dostupno na https://www.eban.org/

Edelman, L. F., Manolova, T. S. i Brush, C. G. (2017). Angel investing: A literature review. *Foundations and Trends in Entrepreneurship*, *13*(4-5), 265-439. https://doi.org/10.1561/0300000051

EIF (b. d.). *European Angels Fund*. Dostupno na https://www.eif.org/

EIF (2026). *Start-up to Scale-up: EIF, HBOR and Croatia scale up partnership to boost venture financing in the country*. Dostupno na https://www.eif.org/press/

Estatuto dos benefícios fiscais, čl. 43.º-A (Programa Semente). *Diário da República, br. 215/89.* Dostupno na https://startupportugal.com/programs/semente/

EstBAN (2025). *Estonian angel investors tirelessly hunt the unicorns: €15.8M invested in startups in 2024*. Dostupno na https://estban.ee/

European Commission (2025). *EU Startup and Scaleup Strategy*. Dostupno na https://research-and-innovation.ec.europa.eu/

Eurostat (2025). Population on 1 January. Dostupno na https://ec.europa.eu/eurostat

Fiscomania (2026). *Investire in startup innovative: guida detrazione 65%.* Dostupno na https://fiscomania.com/

Harrison, R. T., Dibben, M. R. i Mason, C. M. (1997). The role of trust in the informal investor's investment decision: An exploratory analysis. *Entrepreneurship Theory and Practice*, *21*(4), 63-81. https://doi.org/10.1177/104225879702100405

Harrison, R. T., Mason, C. M. i Smith, D. (2015). Heuristics, learning and the business angel investment decision-making process. *Entrepreneurship & Regional Development*, *27*(9-10), 527-554. https://doi.org/10.1080/08985626.2015.1066875

HM Revenue and Customs (2025). HS341 Enterprise Investment Scheme – Income Tax relief. GOV.UK. Dostupno na https://www.gov.uk/

HM Revenue and Customs (2026). HS393 Seed Enterprise Investment Scheme – Income Tax and Capital Gains Tax reliefs. GOV.UK. Dostupno na https://www.gov.uk/

Lefebvre, V., Certhoux, G. i Radu-Lefebvre, M. (2022). Sustaining trust to cross the Valley of Death: A retrospective study of business angels' investment and reinvestment decisions. *Technovation*, *109*, 102159. https://doi.org/10.1016/j.technovation.2020.102159

Macht, S. A. i Robinson, J. (2009). Do business angels benefit their investee companies? *International Journal of Entrepreneurial Behavior & Research*, *15*(2), 187-208. https://doi.org/10.1108/13552550910944575

Mason, C. M. i Harrison, R. T. (2002). Is it worth it? The rates of return from informal venture capital investments. *Journal of Business Venturing*, *17*(3), 211-236.

Mason, C. M. i Harrison, R. T. (2006). After the exit: Acquisitions, entrepreneurial recycling and regional economic development. *Regional Studies, 40*(1), 55-73. https://doi.org/10.1080/00343400500450059

Mason, C. M. i Harrison, R. T. (2008). Measuring business angel investment activity in the United Kingdom: A review of potential data sources. *Venture Capital, 10*(4), 309-330. https://doi.org/10.1080/13691060802380098

Maxwell, A. L., Jeffrey, S. A. i Lévesque, M. (2011). Business angel early stage decision making. *Journal of Business Venturing*, *26*(2), 212-225. https://doi.org/10.1016/j.jbusvent.2009.09.002

Ministarstvo gospodarstva (2025). *Godišnji plan rada Ministarstva gospodarstva za 2026. godinu*. Dostupno na https://mingo.gov.hr/

Porezna uprava (2026). *Dohodak od kapitala po osnovi kapitalnih dobitaka*. Dostupno na https://porezna-uprava.gov.hr/

PwC Portugal (2026). *IRS – Guia Fiscal 2026*. Dostupno na https://www.pwc.pt/

Uredba Komisije (EU) br. 651/2014 o ocjenjivanju određenih kategorija potpora spojivima s unutarnjim tržištem. *Službeni list Europske unije*, L 187/2014.

Van Osnabrugge, M. i Robinson, R. J. (2000). *Angel investing: Matching startup funds with startup companies*. San Francisco: Jossey-Bass.

Wetzel, W. E. (1983). Angels and informal risk capital. *Sloan Management Review*, *24*(4), 23-34.

We Wealth (2026). *Investimenti in startup: dal 2026 salta il 30%, cosa cambia*. Dostupno na https://www.we-wealth.com/

Zakon o porezu na dohodak. Narodne novine, br. 115/16 do 152/24.

Zakon o poticanju razvoja malog gospodarstva. Narodne novine, br. 29/02 do 121/16.

Zakon o poticanju ulaganja. Narodne novine, br. 63/22.

Zakon o unapređenju poduzetničke infrastrukture. Narodne novine, br. 93/13 do 138/21.

# FOSTERING BUSINESS ANGEL INVESTMENT IN CROATIA: TAX ASYMMETRY, EUROPEAN LESSONS AND PROPOSED POLICY MEASURES

***Abstract***

*The purpose of this paper is to analyze the state of the business angel market in Croatia and to propose a public policy framework for its development. The visible business angel market in Croatia is among the least developed in the European Union, despite a growing pipeline of early-stage ventures. Methodologically, the paper combines an analysis of secondary data on the European and Croatian angel markets, a comparative analysis of public policy instruments in selected European countries, and findings from recent behavioral literature on business angel decision-making. The results show that the Croatian tax system treats successful exits from equity investments favorably while offering no incentive for the investment itself, leaving the risk asymmetry that deters private capital from the earliest stages intact, and that comparable small EU member states achieve substantially higher early-stage investment volumes through targeted instruments. On this basis, the paper proposes three sets of measures: tax incentives for investments in innovative start-ups, public co-investment schemes modeled on matching funds, and measures strengthening angel networks and investor education. The limitations of the paper stem from incomplete data on the invisible part of the market and from the absence of an ex ante estimate of the fiscal impact of the proposed measures. The originality of the paper lies in linking, for the first time, insights into business angel behavior with public policy design for the Croatian context, at a moment when the legislative framework is opening.*

***Keywords****: business angels, early-stage financing, public policy, tax incentives, entrepreneurial ecosystem.*

JEL klasifikacija: J21, J24, R23

Izvorni znanstveni rad

# NEUSKLAĐENOST VJEŠTINA NA HRVATSKOM TRŽIŠTU RADA: ANALIZA PREMA TIPOVIMA VJEŠTINA

Mia Despotović*

## SAŽETAK

Rasprava o neusklađenosti vještina (engl. *skill mismatch*) u Hrvatskoj dosad se uglavnom vodila na agregatnoj razini, bez analitičkoga razlučivanja pojedinih tipova vještina. Ovaj rad usmjerava pozornost na samu strukturu vještina te propituje koji tipovi vještina najviše odstupaju pri usporedbi potražnje poslodavaca i ponude registriranih nezaposlenih osoba. Polazna je teza da diferencijacija među tipovima vještina ima izravne implikacije za oblikovanje politika prekvalifikacije. Cilj je rada empirijski izmjeriti neusklađenost zasebno za tri Cedefopova tipa vještina — međusektorske (transverzalne), sektorske i specifične (vezane uz zanimanje) te ih međusobno usporediti. Analiza se temelji na administrativnim podacima Hrvatskoga zavoda za zapošljavanje za travanj 2026. godine o prijavljenim potrebama poslodavaca i registriranim nezaposlenim osobama, povezanima usklađenom taksonomijom prema NKZ-u i HKO-u. Za devetnaest županija izračunava se mjera neusklađenosti utemeljena na Jaccardovu koeficijentu, odnosno Jaccardova udaljenost skupova vještina na potražnoj i ponudbenoj strani. Horizontalna neusklađenost zanimanja mjeri se Duncanovim

* Dr. sc. Mia Despotović, Sveučilište Algebra Bernays, vanjska suradnica (e-mail: mia.despotovic@gmail.com).

indeksom različitosti, a vertikalna dimenzija udjelom niskokvalificiranih osoba (HKO ≤ 2).

Neusklađenost je najveća kod sektorskih vještina (prosjek 80,2 %), a zamjetno niža kod međusektorskih (66,6 %) i specifičnih (66,3 %) vještina. Sektorska neusklađenost statistički je značajno veća od neusklađenosti preostalih dvaju tipova, čime se potvrđuje istraživačka hipoteza, dok se međusektorske i specifične vještine međusobno ne razlikuju. Sektorska neusklađenost prelazi 90 % u pet županija, a najviša je u Zagrebačkoj županiji (97,3 %). Nalazi upućuju na to da se u administrativno evidentiranom segmentu tržišta rada najizraženije odstupanje nalazi kod sektorskih vještina, što podupire razmatranje sektorski i regionalno usmjerenih programa prekvalifikacije razvijenih u suradnji s poslodavcima. Analiza je presječnog karaktera i ograničena na evidencije HZZ-a.

Rezultati otkrivaju jasan i dosljedan redoslijed među tipovima vještina. Neusklađenost je najveća kod sektorskih vještina (prosjek 80,2 %), a zamjetno niža kod međusektorskih (66,6 %) i specifičnih (66,3 %) vještina. Transverzalne vještine najčešće su zastupljene na objema stranama tržišta rada, dok su sektorski specifične vještine najmanje prisutne među nezaposlenima. Prevladavanje sektorske neusklađenosti postojano je u prostoru; u Ličko-senjskoj i Međimurskoj županiji ta vrijednost prelazi 90 %. Prostorno je neusklađenost viša u kontinentalnim i gospodarski slabije razvijenim županijama.

Na tržištu rada obilježenom strukturnim viškom i dugotrajnim nedostatkom radne snage, ovi nalazi pomiču težište analize s kvantitativnih na strukturne elemente: ključno ograničenje nije nedostatak ljudi, već deficit granski specifičnih vještina. To upućuje na važnost ciljanih mjera prekvalifikacije u području sektorskih vještina, oblikovanih u suradnji s djelatnostima koje bilježe nedostatak radnika. Administrativni podaci omogućuju transparentno, dvostrano i po tipu vještina razlučeno mjerenje neusklađenosti na regionalnoj razini.

Analiza je presječnog karaktera (engl. *cross-sectional)* te opisuje strukturne neusklađenosti u jednome vremenskom trenutku, bez obuhvaćanja sezonskih kretanja.

**Ključne riječi:** neusklađenost vještina, tipovi vještina, sektorske vještine, indeks različitosti, Hrvatska.

# 1. UVODNA RAZMATRANJA

Hrvatsko tržište rada u posljednjem je desetljeću doživjelo preobrazbu koja je bitno izmijenila prirodu njegovih strukturnih ograničenja. Stopa registrirane nezaposlenosti spustila se na najniže razine zabilježene od osamostaljenja, dok istodobno raste broj poslodavaca koji prijavljuju poteškoće u popunjavanju radnih mjesta. Takav spoj niske nezaposlenosti i ustrajnoga nedostatka radne snage upućuje na to da se ključno ograničenje više ne nalazi u broju raspoloživih osoba, nego u strukturi njihovih vještina. Problem se time pomiče s kvantitativne na kvalitativnu razinu, a analitički instrumentarij koji je razvijen za razdoblja visoke nezaposlenosti postaje nedostatan za razumijevanje suvremenih neravnoteža.

Dosadašnja rasprava o neusklađenosti vještina (engl. *skill mismatch*) u Hrvatskoj vodila se pretežno na agregatnoj razini. Istraživanja su se usmjeravala na kvalifikacijsku neusklađenost, preobrazovanost ili horizontalnu neusklađenost[1], pri čemu su se vještine tretirale kao jedinstvena i nediferencirana kategorija ljudskog kapitala. Takav pristup daje koristan opći uvid, ali zaklanja činjenicu da se vještine međusobno bitno razlikuju po prenosivosti, načinu stjecanja i brzini zastarijevanja. Transverzalna vještina poput timskoga rada stječe se i prenosi drukčije od granom djelatnosti vezanoga tehničkog znanja, pa posljedično i mjere koje ih nastoje razviti moraju biti odgovarajuće osmišljene.

Ovaj rad polazi od teze da diferencijacija među tipovima vještina ima izravne implikacije za oblikovanje politika prekvalifikacije. Ako se neusklađenost ne raspodjeljuje ravnomjerno među tipovima vještina, onda opće mjere obrazovanja odraslih ne mogu učinkovito odgovoriti na usko svojstvene specifičnom i jednome segmentu strukture vještina. Cilj je rada empirijski izmjeriti neusklađenost zasebno za tri tipa vještina koje razlikuje Europski centar za razvoj strukovnog osposobljavanja (Cedefop)[2] te ih međusobno usporediti na razini županija.

Polazeći od različite prenosivosti i različitih načina stjecanja pojedinih tipova vještina, rad testira istraživačku hipotezu da je prosječna neusklađenost sektorskih vještina na razini županija veća od prosječne neusklađenosti međusektorskih i specifičnih vještina vezanih uz zanimanje (H1). Hipoteza

[1] Horizontalna neusklađenost odnosi se na nesklad između područja obrazovanja i područja traženoga radnog mjesta.

[2] Međusektorske (transverzalne), sektorske i specifične vještine vezane uz zanimanje.

se ispituje uparenim t-testom i Wilcoxonovim testom predznačenih rangova na vrijednostima pokazatelja po županijama (potpoglavlje 3.4.), a odgovor na nju daje se u potpoglavlju 4.1. i u zaključku.

Istraživanje se oslanja na administrativne podatke Hrvatskoga zavoda za zapošljavanje (HZZ) za travanj 2026. godine, čime se omogućuje simetrično promatranje obiju strana tržišta rada: prijavljenih potreba poslodavaca i registriranih nezaposlenih osoba. Za razliku od anketnih pristupa, koji se oslanjaju na samoprocjenu, administrativni izvor omogućuje dvostrano mjerenje utemeljeno na istoj taksonomiji vještina.

Rad je podijeljen u šest poglavlja. Nakon uvodnih razmatranja, drugo poglavlje donosi teorijski okvir i pregled dosadašnjih istraživanja. Treće poglavlje opisuje podatke i metodološki postupak, četvrto predstavlja rezultate, peto ih raspravlja u kontekstu javnih politika, a šesto sadrži zaključna razmatranja i ograničenja analize.

# 2. TEORIJSKI OKVIR I PREGLED DOSADAŠNJIH ISTRAŽIVANJA

## 2.1. Pojmovno određenje neusklađenosti

Neusklađenost vještina (engl. *skill mismatch*) opisuje situaciju u kojoj se vještine i kvalifikacije koje posjeduje radna snaga razlikuju od vještina i kvalifikacija koje zahtijevaju radna mjesta (Sala Lorda, 2011). McGuinness, Pouliakas i Redmond (2018.) upozoravaju da se pod istim pojmom u literaturi skriva više različitih konstrukata koji se mjere različitim instrumentima i zahtijevaju različite mjere javnih politika. Uobičajeno se razlikuju vertikalna neusklađenost, koja se odnosi na razinu kvalifikacije, i horizontalna neusklađenost, koja se odnosi na područje ili sadržaj kvalifikacije. Neusklađenost vještina u užem smislu odnosi se na stvarni sadržaj vještina potrebnih za rad i konceptualno je najbliža horizontalnoj dimenziji, ali se od nje razlikuje po tome što se mjeri na razini pojedinačnih vještina, a ne na razini zanimanja ili obrazovnoga programa.

Makroekonomska literatura neusklađenost promatra kao izvor strukturne nezaposlenosti. Şahin, Song, Topa i Violante (2014) pokazuju da neusklađenost između raspodjele slobodnih radnih mjesta i raspodjele nezaposlenih osoba objašnjava znatan dio porasta nezaposlenosti tijekom recesije, pri čemu naglašavaju da se učinak razlikuje ovisno o tome promatra

li se neusklađenost po zanimanjima, djelatnostima ili prostornim jedinicama. Ta pouka izravno je relevantna i za analizu vještina: razina agregacije na kojoj se neusklađenost mjeri bitno određuje sliku koja se dobiva.

## 2.2. Tipologija vještina

Cedefop (2010) razlikuje vještine prema stupnju prenosivosti između različitih radnih okruženja. Međusektorske ili transverzalne vještine primjenjive su u velikom broju zanimanja i djelatnosti te obuhvaćaju komunikaciju, organizaciju rada, rješavanje problema i digitalnu pismenost. Sektorske vještine vezane su uz određenu gospodarsku granu i prenosive su unutar nje, ali ne i izvan nje. Specifične vještine vezane su uz jedno zanimanje ili jedno radno mjesto i imaju najmanju prenosivost.

Ta tipologija nije samo deskriptivna nego ima jasnu ekonomsku logiku. Stupanj prenosivosti vještina određuje tko snosi troškove i ima poticaj ulagati u njihovo stjecanje, kao i brzinu kojom se tržišne neravnoteže mogu otkloniti. Transverzalne vještine stječu se primarno kroz opće obrazovanje i investicija su pojedinca i/ili države. Sektorske vještine zahtijevaju blisku povezanost s konkretnom djelatnošću te se najčešće stječu kombinacijom strukovnoga obrazovanja i radnoga iskustva. S tim u vezi, Cedefop (2020) u pregledu hrvatskoga sustava strukovnoga obrazovanja upozorava upravo na slabost te poveznice između obrazovnih programa i stvarnih potreba pojedinih djelatnosti. Naposljetku, specifične vještine razvijaju se kroz specijaliziranu obuku na samom radnom mjestu, što privlači najveći interes poslodavaca za ulaganje jer izravno podižu produktivnost unutar poduzeća, a rizik od odljeva radnika je minimalan.

## 2.3. Hrvatski kontekst i istraživačka praznina

Hrvatska istraživanja neusklađenosti dominantno su bila usmjerena na obrazovnu dimenziju izazova, odnosno na nesklad između formalnih kvalifikacija i radnih mjesta. U domaćem istraživačkom kontekstu, Bečić (2013, 2014) empirijski operacionalizira fenomen vertikalne neusklađenosti kroz analizu preobrazovanosti, demonstrirajući da znatan udio radne snage zauzima radna mjesta koja zahtijevaju nižu razinu kvalifikacijske složenosti od one koju su radnici stekli formalnim obrazovanjem. Bejaković i Mrnjavac (2014) fokus istraživanja premještaju na neusklađenost vještina te kritički

evaluiraju analitičke instrumente za predviđanje budućih potreba tržišta rada, detektirajući pritom institucionalne nedostatke u mehanizmima dugoročnog predviđanja potreba za vještinama. Strukturnu dimenziju problema adresira Tomić (2014) ispitujući strukturalni suodnos između alokacijske neusklađenosti zanimanja i perzistentnosti strukturne nezaposlenosti koristeći indeks disimilacije. Naposljetku, Obadić i Viljevac (2024) makroekonomsku perspektivu proširuju komparativnom analizom neusklađenosti zanimanja, pozicionirajući specifičnosti hrvatskoga tržišta rada u širi kontekst odabranih država članica Europske unije. Prostornu dimenziju hrvatskoga tržišta rada obrađuju Håkansson i Bejaković (2020), koji povezuju uska grla regije s niskom prostornom mobilnošću radne snage. Bartolini (2024) problem nedostatka radne snage smješta u makroekonomski okvir i upozorava na demografska ograničenja ponude rada. Europska komisija (2020) u izvješću o Hrvatskoj navodi neusklađenost vještina među ključnim preprekama rastu produktivnosti, a Cedefop (2021, 2024) u okviru pokazatelja neusklađenosti Hrvatsku svrstava među države s izraženim strukturnim odstupanjima.

Unatoč razvijenosti te literature, izostaje istraživanje koje bi neusklađenost mjerilo zasebno po tipovima vještina, i to na obje strane tržišta rada istodobno. Upravo tu prazninu ovaj rad nastoji popuniti.

# 3. PODACI I METODOLOGIJA

## 3.1. Izvori podataka

Empirijska analiza u ovome radu temelji se na administrativnim podacima Hrvatskoga zavoda za zapošljavanje (HZZ) za travanj 2026. godine. Potražnu stranu tržišta rada predstavljaju registrirane potrebe poslodavaca za radnicima (prijavljena slobodna radna mjesta), dok njegovu ponudbenu stranu čine službeno evidentirane nezaposlene osobe. Simetričnost i usporedivost obiju strana osigurana je primjenom usklađene taksonomije koja integrira šifarni sustav Nacionalne klasifikacije zanimanja (NKZ 10) i razine složenosti definirane Hrvatskim kvalifikacijskim okvirom (HKO). Svakoj analitičkoj jedinici, neovisno o tome radi li se o zahtjevu radnoga mjesta ili profilu nezaposlene osobe, pridružen je pripadajući skup vještina, preuzet iz HZZ-ova registra vještina i klasificiran prema Cedefopovoj tripartitnoj tipologiji. Razvrstavanje vještina u tri tipa nije rezultat autorske klasifikacije, nego je preuzeto iz samoga izvora. Analitički moduli HZZ-a pod nazivom „Analize bazirane na vještinama“ prikazuju vještine u tri odvojena bloka –

međusektorske, sektorske i specifične – i to istovjetnom strukturom na obje strane tržišta rada: u modulu koji se odnosi na registrirane nezaposlene osobe i u modulu koji se odnosi na prijavljene potrebe poslodavaca. Svaka je vještina unutar izvornoga skupa podataka pridružena točno jednom tipu, u skladu s tipologijom izloženom u potpoglavlju 2.2. Tipologija je time simetrična po konstrukciji, a razvrstavanje ne uključuje diskrecijsku prosudbu istraživača, čime se uklanja jedan od uobičajenih izvora mjerne pristranosti u istraživanjima neusklađenosti vještina. Nastavno, rezultati opisuju registrirani segment tržišta rada obuhvaćen administrativnim evidencijama HZZ-a, a ne ukupnu ponudu i potražnju rada u Hrvatskoj.

Nazivi vještina preuzeti su iz obaju modula kao tekstualne oznake te normalizirani s ciljem osiguranja usporedivosti: pretvoreni su u mala slova, očišćeni od rodnih varijanti naziva, dijakritičkih znakova i interpunkcije, uz sažimanje višestrukih razmaka. Skupovi vještina na strani potražnje i na strani ponude oblikuju se nad tim oznakama, a podudaranje je egzaktno[3]. Odabrani pristup time je naglašeno konzervativan: preostale varijacije u tekstualnom zapisu smanjuju stupanj utvrđenog preklapanja skupova i posljedično vode prema nešto višim (gornjim) vrijednostima izmjerene neusklađenosti.

Analitička jedinica jest županija. Od ukupno dvadeset i jedne teritorijalne jedinice u radnom uzorku zadržano je devetnaest. Izostavljene su Brodsko-posavska i Koprivničko-križevačka županija, budući da podaci za registrirane nezaposlene osobe podaci za navedene županije u razdoblju provedbe istraživanja nisu raspoloživi. Dvije izostavljene županije obuhvaćaju 4.553 registrirane nezaposlene osobe (Brodsko-posavska 3.587, Koprivničko-križevačka 966), odnosno 6,7 % od ukupno 67.521 osobe u evidenciji HZZ-a u travnju 2026. godine[4]. Pokazatelji su izračunati zasebno za svaku županiju i svaki tip vještine.

## 3.2. Mjerenje neusklađenosti vještina

Središnji pokazatelj rada jest mjera utemeljena na Jaccardovu koeficijentu (Jaccard, 1912). Za svaku županiju i svaki tip vještine oblikuju se dva skupa: skup vještina koje se pojavljuju u prijavljenim potrebama poslodavaca, označen s D, i skup vještina koje se pojavljuju kod registriranih nezaposlenih

[3] Spajanje gotovo istovjetnih oznaka po prosudbi nije primijenjeno.

[4] Broj registriranih nezaposlenih osoba po županijama prikazan je u Dodatku A.

osoba, označen s S. Jaccardov koeficijent definira se kao omjer veličine presjeka i veličine unije tih dvaju skupova:

$$J = |D \cap S| / |D \cup S|$$

Mjera neusklađenosti dobiva se kao komplement toga koeficijenta:

$$M = (1 - J) \times 100$$

Vrijednost pokazatelja kreće se od 0 do 100 %. Vrijednost 0 označava potpuno preklapanje skupova vještina na obje strane tržišta rada, a vrijednost 100 % potpuni izostanak preklapanja. Prednost je toga pristupa simetričnost: mjera jednako tretira vještine koje poslodavci traže, a nezaposleni ih nemaju, i vještine koje nezaposleni posjeduju, a poslodavci ih ne traže. Osim toga, pokazatelj ne pretpostavlja da je jedna strana tržišta referentna, što je čest problem mjera utemeljenih isključivo na potražnji.

Mjera ipak nije neosjetljiva na veličinu promatranih skupova. Budući da se presjek stavlja u odnos prema uniji, širi rječnik vještina pri istom broju zajedničkih elemenata proizvodi višu vrijednost pokazatelja. Usporedba među tipovima vještina stoga zahtijeva provjeru jesu li unije skupova međusobno usporedive. Ako bi se jedan tip u podacima pojavljivao s bitno bogatijim rječnikom, njegova bi viša neusklađenost mogla biti posljedica konstrukcije mjere, a ne stvarne neravnoteže. Ta se mogućnost provjerava u nastavku.

## 3.3. Pomoćni pokazatelji

Radi smještanja glavnoga nalaza u širi kontekst izračunavaju se dva pomoćna pokazatelja. Horizontalna neusklađenost zanimanja mjeri se Duncanovim indeksom različitosti (Duncan i Duncan, 1955), koji izražava udio jedne raspodjele koji bi se morao preraspodijeliti da bi se izjednačila s drugom. U ovom slučaju uspoređuju se raspodjela prijavljenih potreba poslodavaca i raspodjela registriranih nezaposlenih po skupinama zanimanja prema NKZ-u. Nazivi zanimanja usklađeni su postupkom normalizacije opisanim u potpoglavlju 3.1. Za oznake bez egzaktnoga podudaranja dodatno su mjerom tekstualne sličnosti niza (Ratcliff/Obershelp) utvrđeni kandidati za spajanje sa sličnošću od najmanje 0,80. Utvrđeno je sedamnaest takvih parova. Nakon ručne provjere prihvaćena su četiri para koja predstavljaju pravopisne pogreške odnosno pogreške pri očitavanju istoga naziva zanimanja (drvoprerađivački radnik, knjigovođa, njegovatelj, rukovatelj). Preostalih

trinaest parova označava sadržajno različita zanimanja i namjerno nije spojeno, kako se ne bi umjetno smanjila izmjerena neusklađenost.

Vertikalna dimenzija aproksimira se udjelom registriranih nezaposlenih osoba s kvalifikacijom na razini HKO ≤ 2, odnosno udjelom niskokvalificiranih osoba u evidenciji.

Pregled svih korištenih pokazatelja donosi se u Tablici 1.

**Tablica 1. Pokazatelji neusklađenosti korišteni u analizi**

| Pokazatelj | Operacionalizacija | Razina izračuna |
|---|---|---|
| Međusektorske (transverzalne) vještine | 1 − Jaccardov koeficijent nad skupovima transverzalnih vještina | županija |
| Sektorske vještine | 1 − Jaccardov koeficijent nad skupovima granski vezanih vještina | županija |
| Specifične vještine (vezane uz zanimanje) | 1 − Jaccardov koeficijent nad skupovima vještina vezanih uz jedno zanimanje | županija |
| Horizontalna neusklađenost zanimanja | Duncanov indeks različitosti po skupinama zanimanja prema NKZ-u | županija |
| Vertikalna dimenzija | Udio registriranih nezaposlenih s kvalifikacijom na razini HKO ≤ 2 | županija |

Izvor: izrada autora.

## 3.4. Statističko testiranje razlika među tipovima vještina

Budući da se pokazatelj izračunava zasebno za svaku županiju i svaki tip vještine, razlike među tipovima mogu se ispitati na uparenim opažanjima. Za svaki par tipova vještina provodi se upareni t-test na devetnaest županija, a kao neparametrijska provjera robusnosti Wilcoxonov test predznačenih rangova, koji ne pretpostavlja normalnost razdiobe razlika. Uparena struktura ima dodatnu prednost jer se usporedba provodi unutar iste županije, čime se uklanja utjecaj regionalnih obilježja koja djeluju na sve tipove vještina istodobno.

# 4. REZULTATI

## 4.1. Neusklađenost prema tipu vještine

Rezultati otkrivaju jasan i dosljedan redoslijed među tipovima vještina. Prosječna neusklađenost najveća je kod sektorskih vještina i iznosi 80,2 %, dok je kod međusektorskih vještina zamjetno niža i iznosi 66,6 %, a kod specifičnih vještina vezanih uz zanimanje 66,3 %. Razlika između sektorskih vještina i preostala dva tipa iznosi oko četrnaest postotnih bodova, dok je razlika između međusektorskih i specifičnih vještina zanemariva i iznosi svega tri desetinke postotnoga boda. Grafički prikaz istog odnosa donosi Slika 1.

**Slika 1. Prosječna neusklađenost prema tipu vještine, travanj 2026. (%)**

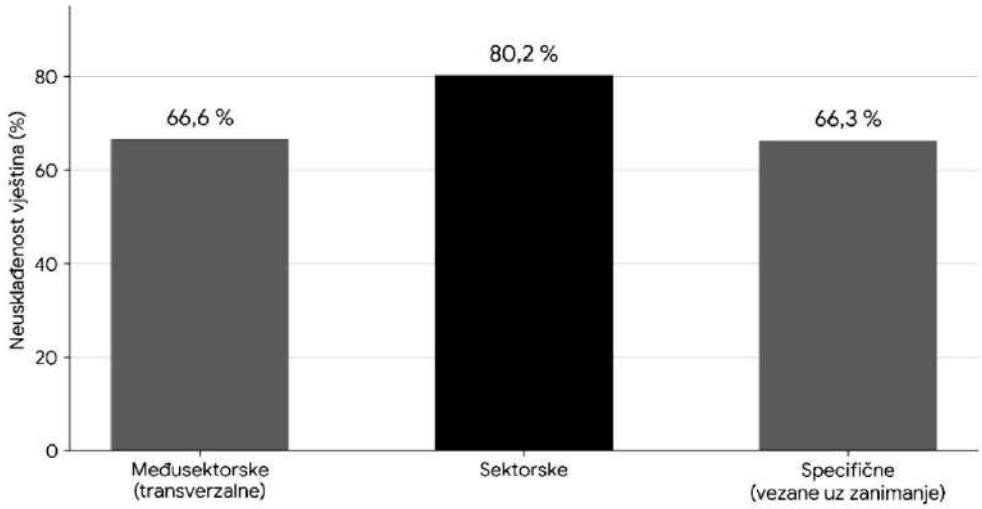


Izvor: izračun autora prema administrativnim podacima Hrvatskoga zavoda za zapošljavanje (2026.).

Razlike među tipovima vještina sustavne su i statistički značajne. Upareni t-test na devetnaest županija pokazuje da sektorska neusklađenost nadmašuje međusektorsku za prosječno 13,7 postotnih bodova ($t(18) = 5,62$; $p < 0,001$), a specifičnu za 13,9 postotnih bodova ($t(18) = 3,75$; $p = 0,001$). Razlika između međusektorskih i specifičnih vještina nije statistički značajna i iznosi svega 0,3 postotna boda ($t(18) = 0,07$; $p = 0,942$). Wilcoxonov test predznačenih rangova

vodi na istovjetne zaključke, što upućuje na to da nalazi ne ovise o pretpostavci normalnosti. Rezultati testova prikazani su u Tablici 2.

**Tablica 2. Upareni testovi razlika u neusklađenosti među tipovima vještina, travanj 2026.**

| Usporedba | Razlika (pb) | t(18) | p | Wilcoxonov p |
|---|---|---|---|---|
| Sektorske − međusektorske | +13,7 | 5,62 | < 0,001 | < 0,001 |
| Sektorske − specifične | +13,9 | 3,75 | 0,001 | 0,002 |
| Međusektorske − specifične | +0,3 | 0,07 | 0,942 | 0,984 |

Izvor: izračun autora prema administrativnim podacima Hrvatskoga zavoda za zapošljavanje (2026.). *Napomena:* upareni t-test i Wilcoxonov test predznačenih rangova na 19 županija; pb označava postotni bod.

Nalaz se time može precizirati. Sektorske vještine sustavno odudaraju od preostala dva tipa, dok su međusektorske i specifične vještine međusobno statistički nerazlučive. Redoslijed pritom nije univerzalan na razini pojedinačne županije pa sektorske vještine bilježe najvišu vrijednost u dvanaest od devetnaest županija, ali je razlika u prosjeku dosljedna i znatna. Time je potvrđena postavljena istraživačka hipoteza da je sektorska neusklađenost statistički značajno veća i od međusektorske i od specifične neusklađenosti, pri čemu se međusektorske i specifične vještine međusobno statistički značajno ne razlikuju.

Prije sadržajnoga tumačenja potrebno je isključiti mogućnost da uočena razlika proizlazi iz same konstrukcije mjere. Kako je naznačeno ranije, vrijednost pokazatelja raste s veličinom unije skupova, pa bi viša sektorska neusklađenost mogla odražavati bogatiji rječnik sektorskih vještina, a ne stvarno slabije preklapanje dviju strana tržišta rada. Podaci tu mogućnost ne potvrđuju. Prosječna unija skupova iznosi 58,3 kod međusektorskih, 64,8 kod sektorskih i 59,6 kod specifičnih vještina, pa su razlike u širini rječnika umjerene. Presjek skupova, nasuprot tomu, kod sektorskih vještina iznosi 12,2 naspram 19,1 kod međusektorskih i 18,9 kod specifičnih, što je oko trećine manje. Razlika u pokazatelju stoga proizlazi iz slabijega preklapanja, a ne iz veličine promatranih skupova. Vrijednosti su prikazane u Tablici 3.

**Tablica 3. Prosječna veličina skupova vještina prema tipu vještine, travanj 2026.**

| Tip vještine | Presjek skupova | Unija skupova | Neusklađenost (%) |
|---|---|---|---|
| Međusektorske | 19,1 | 58,3 | 66,6 |
| Sektorske | 12,2 | 64,8 | 80,2 |
| Specifične | 18,9 | 59,6 | 66,3 |

Izvor: izračun autora prema administrativnim podacima Hrvatskoga zavoda za zapošljavanje (2026.). *Napomena:* prosječan broj elemenata po županiji (N = 19).

Sadržajno tumačenje toga redoslijeda proizlazi iz strukture skupova vještina na obje strane tržišta rada. Transverzalne vještine najčešće su zastupljene i u prijavljenim potrebama poslodavaca i u evidenciji nezaposlenih, pa je njihovo preklapanje razmjerno visoko. Sektorski vezane vještine, nasuprot tomu, redovito se pojavljuju u potražnji poslodavaca, ali su najmanje prisutne u skupu vještina registriranih nezaposlenih osoba. Upravo taj asimetričan raspored proizvodi najviše vrijednosti pokazatelja neusklađenosti.

Vrijednost pokazatelja za specifične vještine zahtijeva oprezno tumačenje. Njihova prosječna neusklađenost gotovo je jednaka neusklađenosti međusektorskih vještina, a jednake su i prosječne veličine skupova: unija iznosi 59,6 kod specifičnih naspram 58,3 kod međusektorskih vještina, a presjek 18,9 naspram 19,1. Niža neusklađenost specifičnih u odnosu na sektorske vještine stoga se ne može pripisati užem rječniku specifičnih vještina, nego ponajprije odražava veće preklapanje skupova na dvjema stranama tržišta rada. Taj nalaz ipak ne treba tumačiti kao dokaz da tržište rada nema poteškoća s uskospecijaliziranim kadrom jer primijenjena mjera bilježi samo binarnu prisutnost oznake vještine, a ne učestalost njezina pojavljivanja, intenzitet potražnje ni razinu ovladanosti vještinom.

## 4.2. Prostorna raspodjela

Prevladavanje sektorske neusklađenosti u velikoj je mjeri postojano u prostoru. U dvanaest od devetnaest promatranih županija sektorske vještine bilježe najvišu vrijednost pokazatelja među tri tipa vještina. U pet županija ta vrijednost prelazi 90 %: u Zagrebačkoj iznosi 97,3 %, u Ličko-senjskoj 95,3

%, u Virovitičko-podravskoj 93,2 %, u Međimurskoj 91,8 % i u Sisačko-moslavačkoj 90,3 %. Najnižu vrijednost bilježi Istarska županija s 50,0 %. Raspodjela po županijama prikazana je na Slici 2.

**Slika 2. Neusklađenost sektorskih vještina prema županijama, travanj 2026. (%)**

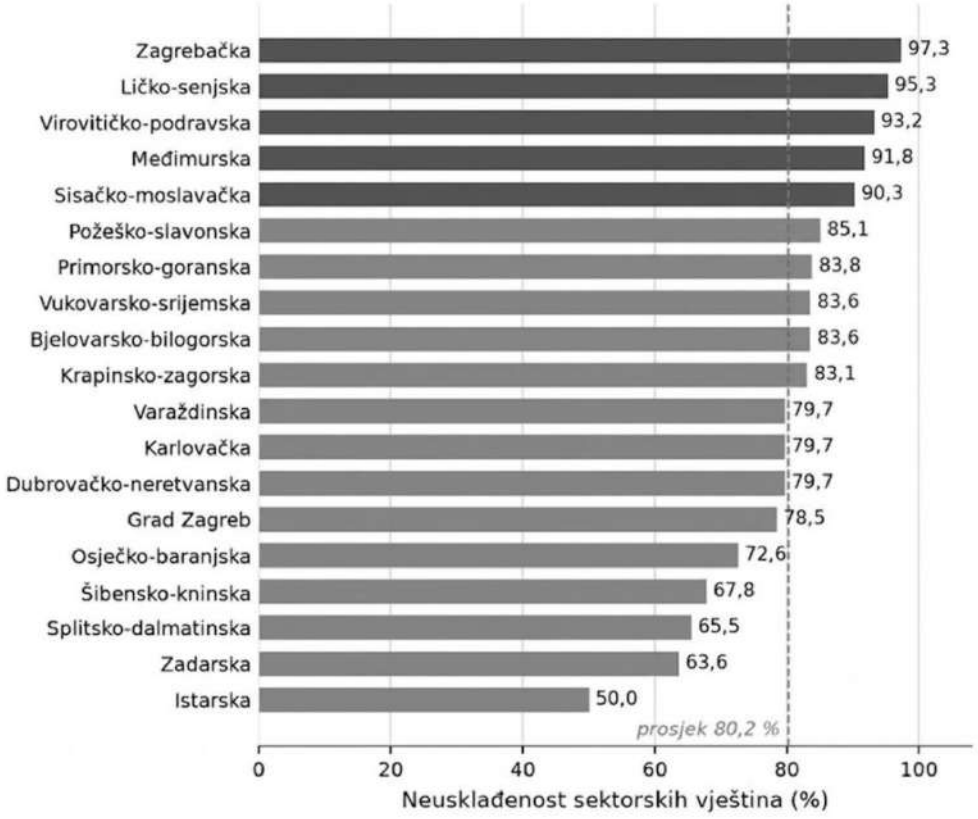


Izvor: izračun autora prema administrativnim podacima Hrvatskoga zavoda za zapošljavanje (2026.).

Za opisnu usporedbu županije su razvrstane u kontinentalnu i priobalnu skupinu prema podjeli navedenoj u napomeni uz Tablicu 4. Prosječna neusklađenost vještina u kontinentalnim županijama iznosi 74,0 %, a u priobalnima 66,0 %; kod sektorskih vještina razlika je izraženija i iznosi 84,9

% naspram 72,3 %. Razlike nisu statistički značajne na razini od 5 % (Mann-Whitneyjev test: p = 0,167 za prosječnu i p = 0,082 za sektorsku neusklađenost), pa ih treba tumačiti kao opisni obrazac. Povezanost s razinom razvijenosti provjerena je prema razvrstavanju županija u četiri skupine razvijenosti (Vlada Republike Hrvatske, 2024). Spearmanov koeficijent korelacije rangova između skupine razvijenosti i prosječne neusklađenosti vještina iznosi −0,43 (p = 0,065; N = 19), a za sektorsku neusklađenost −0,40 (p = 0,092). Smjer povezanosti upućuje na višu neusklađenost u slabije razvijenim županijama: u najslabije razvijenoj, I. skupini prosječna neusklađenost iznosi 80,0 %, naspram 67,0 % do 69,6 % u ostalim skupinama. Povezanost ipak nije statistički značajna na razini od 5 %, pa rad ne dokazuje sustavnu povezanost neusklađenosti s gospodarskom razvijenošću. Obrazac je u skladu s nalazima o regionalnim uskim grlima i niskoj prostornoj mobilnosti radne snage (Håkansson i Bejaković, 2020), ali zahtijeva daljnju provjeru na većem broju opažanja.

Pri tumačenju te razlike potreban je oprez. Podaci se odnose na travanj, mjesec koji prethodi glavnoj turističkoj sezoni, pa dio odstupanja između priobalnih i kontinentalnih županija može odražavati sezonski raspored prijavljenih potreba, a ne trajnu strukturnu razliku. Ta se ograda podrobnije razmatra u šestom poglavlju. Potpuni pregled vrijednosti po županijama i tipovima vještina donosi Tablica 4.

**Tablica 4. Neusklađenost vještina prema županijama i tipu vještine, travanj 2026. (%)**

| Županija | Međusektorske | Sektorske | Specifične | Prosjek |
|---|---|---|---|---|
| Požeško-slavonska | 76,6 | 85,1 | 94,6 | 85,4 |
| Virovitičko-podravska | 72,1 | 93,2 | 87,1 | 84,2 |
| Sisačko-moslavačka | 70,0 | 90,3 | 78,5 | 79,6 |
| Ličko-senjska | 73,3 | 95,3 | 69,5 | 79,4 |
| Bjelovarsko-bilogorska | 63,2 | 83,6 | 89,9 | 78,9 |
| Grad Zagreb | 80,0 | 78,5 | 74,6 | 77,7 |
| Zagrebačka | 81,3 | 97,3 | 53,7 | 77,4 |
| Dubrovačko-neretvanska | 66,1 | 79,7 | 81,8 | 75,9 |

| Županija | Međusektorske | Sektorske | Specifične | Prosjek |
|---|---|---|---|---|
| Primorsko-goranska | 76,6 | 83,8 | 63,8 | 74,7 |
| Međimurska | 61,4 | 91,8 | 66,1 | 73,1 |
| Vukovarsko-srijemska | 66,7 | 83,6 | 61,4 | 70,6 |
| Splitsko-dalmatinska | 60,7 | 65,5 | 83,8 | 70,0 |
| Karlovačka | 69,5 | 79,7 | 53,7 | 67,6 |
| Krapinsko-zagorska | 58,5 | 83,1 | 53,7 | 65,1 |
| Osječko-baranjska | 58,9 | 72,6 | 61,4 | 64,3 |
| Varaždinska | 50,0 | 79,7 | 61,4 | 63,7 |
| Šibensko-kninska | 74,2 | 67,8 | 31,9 | 58,0 |
| Zadarska | 51,0 | 63,6 | 45,1 | 53,2 |
| Istarska | 54,7 | 50,0 | 47,1 | 50,6 |
| **Prosjek** | **66,6** | **80,2** | **66,3** | **71,0** |

Izvor: izračun autora prema administrativnim podacima Hrvatskoga zavoda za zapošljavanje (2026.). *Napomena:* u kontinentalne županije ubrajaju se Bjelovarsko-bilogorska, Grad Zagreb, Karlovačka, Krapinsko-zagorska, Međimurska, Osječko-baranjska, Požeško-slavonska, Sisačko-moslavačka, Varaždinska, Virovitičko-podravska, Vukovarsko-srijemska i Zagrebačka (12), a u priobalne Dubrovačko-neretvanska, Istarska, Ličko-senjska, Primorsko-goranska, Splitsko-dalmatinska, Šibensko-kninska i Zadarska (7). Ličko-senjska županija svrstana je u priobalne zbog izlaza na more. Brodsko-posavska i Koprivničko-križevačka županija nisu uključene zbog razloga navedenih u potpoglavlju 3.1.

## 4.3. Horizontalna i vertikalna dimenzija

Pomoćni pokazatelji smještaju glavni nalaz u širi okvir. Duncanov indeks različitosti po skupinama zanimanja iznosi u prosjeku 65,4 %, uz medijan od 65,7 %, a kreće se od 50,9 % u Istarskoj do 81,5 % u Požeško-slavonskoj županiji. To znači da bi u prosječnoj županiji gotovo dvije trećine jedne strane tržišta rada trebalo preraspodijeliti među skupinama zanimanja da bi se postiglo podudaranje s drugom stranom.

Udio registriranih nezaposlenih osoba s kvalifikacijom na razini HKO ≤ 2 iznosi u prosjeku 25,1 %, uz znatnu raspršenost — od 12,0 % u Splitsko-dalmatinskoj do 47,7 % u Međimurskoj županiji. Vrijednosti pomoćnih pokazatelja po županijama donosi Tablica 5.

**Tablica 5. Duncanov indeks različitosti i udio niskokvalificiranih osoba prema županijama, travanj 2026. (%)**

| Županija | Duncanov indeks različitosti | Udio nezaposlenih s HKO ≤ 2 |
|---|---|---|
| Požeško-slavonska | 81,5 | 18,6 |
| Međimurska | 78,2 | 47,7 |
| Primorsko-goranska | 75,2 | 18,3 |
| Ličko-senjska | 73,5 | 37,3 |
| Krapinsko-zagorska | 70,1 | 24,9 |
| Zagrebačka | 69,8 | 22,8 |
| Dubrovačko-neretvanska | 69,7 | 16,9 |
| Grad Zagreb | 68,6 | 16,6 |
| Virovitičko-podravska | 68,5 | 30,8 |
| Karlovačka | 65,7 | 29,3 |
| Sisačko-moslavačka | 65,1 | 38,7 |
| Bjelovarsko-bilogorska | 63,8 | 27,8 |
| Zadarska | 60,3 | 19,3 |
| Šibensko-kninska | 58,3 | 20,7 |
| Varaždinska | 57,4 | 28,2 |
| Vukovarsko-srijemska | 56,3 | 17,4 |
| Osječko-baranjska | 54,8 | 29,5 |
| Splitsko-dalmatinska | 54,7 | 12,0 |
| Istarska | 50,9 | 20,9 |
| **Prosjek** | **65,4** | **25,1** |

Izvor: izračun autora prema administrativnim podacima Hrvatskoga zavoda za zapošljavanje (2026.).

Usporedba pokazatelja upućuje na umjereno jaku povezanost između neusklađenosti vještina i neusklađenosti zanimanja pa Pearsonov koeficijent korelacije između prosječne neusklađenosti vještina i Duncanova indeksa iznosi 0,69 (p = 0,001; 95 %-tni interval pouzdanosti od 0,34 do 0,87; N =

19). Povezanost s udjelom niskokvalificiranih osoba znatno je slabija, iznosi 0,21 i nije statistički značajna ($p = 0,40$; 95 %-tni interval pouzdanosti od −0,27 do 0,60), što upućuje na to da se neusklađenost vještina ne može svesti na razinu formalne kvalifikacije. Drugim riječima, županije s visokom neusklađenošću vještina nisu nužno one s najvećim udjelom niskokvalificiranih nezaposlenih osoba.

# 5. RASPRAVA

Nalazi ovoga rada pomiču težište analize neusklađenosti s kvantitativnih na strukturne elemente. Na tržištu rada obilježenom rekordno niskom stopom registrirane nezaposlenosti i istodobnim, ustrajnim strukturnim nedostatkom radne snage, nalazi upućuju na to da u promatranom, administrativno evidentiranom segmentu tržišta rada važnu ulogu ima manjak sektorskih vještina svojstvenih pojedinim granama djelatnosti, a ne samo broj raspoloživih radno aktivnih osoba. Taj nalaz upućuje na potrebu da se pri oblikovanju mjera aktivne politike tržišta rada više pozornosti posveti sadržaju i sektorskoj relevantnosti vještina.

Prvo, opće mjere obrazovanja odraslih usmjerene na transverzalne vještine vjerojatno ne pogađaju žarište najvećega izmjerenog nesklada. Iako su takve intervencije intrinzično vrijedne i dugoročno pridonose općoj zapošljivosti, podaci upućuju na to da je preklapanje transverzalnih vještina između ponudbene i potražne strane tržišta rada razmjerno visoko. Stoga samo povećanje sredstava za opće programe usmjerene na transverzalne vještine vjerojatno ne bi bilo dovoljno za ublažavanje uočenoga sektorskog nesklada, pa bi takva ulaganja trebalo kombinirati s mjerama koje odgovaraju na potrebe pojedinih djelatnosti.

Drugo, programi prekvalifikacije i dokvalifikacije mogli bi se snažnije usmjeriti na stjecanje sektorskih vještina, osobito kroz izravna sektorska partnerstva s industrijama koje bilježe najveći deficit radne snage. Budući da su sektorske vještine prenosive uglavnom unutar pojedine ekonomske grane, njihovo usvajanje vjerojatno zahtijeva intenzivniju inkluziju poslodavaca u proces kurikularnoga oblikovanja i provedbe nego što je to uobičajeno kod generičkih edukacijskih programa. Modeli utemeljeni na učenju na radnome mjestu (od engl. *work-based learning*) i namjenskim institucionalnim konzorcijima stoga mogu biti bolje prilagođeni razvoju sektorskih vještina od standardiziranih tečajeva lišenih takvog konteksta.

Treće, prostorna distribucija empirijskih nalaza upućuje na potrebu za razmatranjem regionalno diferenciranih mjera. Županije u kojima stopa sektorske neusklađenosti premašuje 90 % mogle bi zahtijevati drukčiju konfiguraciju i intenzitet instrumenata od onih u kojima se ta vrijednost kreće oko 50 %. Unificirani, centralizirani nacionalni programi u nekim bi područjima mogli biti predimenzionirani, a u drugima nedostatni za ublažavanje lokalnih uskih grla. Zbog presječnoga dizajna i moguće sezonalnosti podataka taj nalaz ipak treba promatrati kao podlogu za daljnje praćenje, a ne kao dokaz uzročne veze između teritorijalnih obilježja i intenziteta neusklađenosti.

Četvrto, odsutnost snažne korelacije između mjerene neusklađenosti vještina i udjela niskokvalificiranih osoba u evidenciji upućuje na moguća ograničenja onih politika koje se oslanjaju isključivo na podizanje formalne razine kvalifikacija. Podizanje formalne razine kvalifikacija možda neće riješiti problem deficitarnog sadržaja vještina *per se* ako obrazovni ishodi nisu usko i granom djelatnosti usmjereni prema tehnološkim zahtjevima radnih mjesta.

Konačno, metodološki doprinos rada očituje se u verifikaciji da administrativni podaci omogućuju transparentno, simetrično i po tipu vještina deagregirano mjerenje neusklađenosti na subnacionalnoj razini. Za razliku od anketnih pristupa opterećenih subjektivnim samoprocjenama, ovakav pristup omogućuje kontinuiranu replikaciju uz minimalne marginalne troškove, čime se postavlja analitički temelj za dugoročni monitoring i evaluaciju učinaka javnih politika.

## 6. ZAKLJUČNA RAZMATRANJA

U ovome je radu empirijski kvantificirana neusklađenost vještina na hrvatskom tržištu rada odvojeno za tri Cedefopova teorijska tipa vještina, koristeći administrativne podatke Hrvatskoga zavoda za zapošljavanje za travanj 2026. godine. Kao operativni instrument mjerenja primijenjena je Jaccardova udaljenost (kao komplementarni indeks Jaccardova koeficijenta sličnosti skupova). Rezultati upućuju na jasan hijerarhijski redoslijed: neusklađenost doseže svoj maksimum kod sektorskih vještina (80,2 %), dok je zamjetno niža i međusobno konvergentna kod međusektorskih (66,6 %) i specifičnih vještina (66,3 %). Time je potvrđena istraživačka hipoteza H1 prema kojoj je neusklađenost sektorskih vještina veća od neusklađenosti međusektorskih i specifičnih vještina. Sektorske vještine bilježe najvišu

neusklađenost u dvanaest od devetnaest županija, a više vrijednosti u kontinentalnim i slabije razvijenim županijama valja tumačiti kao opisni obrazac koji nije statistički značajan.

Središnja poruka rada jest da konvencionalno, agregatno mjerenje neusklađenosti zamagljuje stvarnu anatomiju problema. Tek analitičko razlučivanje po tipovima vještina upućuje na to da se u administrativno evidentiranom segmentu hrvatskoga tržišta rada izraženije strukturno odstupanje pojavljuje kod granski specifičnih kompetencija nego u domeni općih ili, s druge strane, usko specijaliziranih, poduzeću svojstvenih vještina. Nalaz ne znači da opće ili specifične vještine nisu važne, niti omogućuje zaključke o ponudi i potražnji rada izvan evidencija HZZ-a, ali može poslužiti kao podloga za usmjeravanje programa prekvalifikacije prema sektorskom sadržaju i potrebama poslodavaca.

Provedena analiza, međutim, implicira i određena ograničenja. Budući da je riječ o presječnom istraživanju (*cross-sectional analysis*) koje fiksira stanje u jednoj vremenskoj točki, ono ne obuhvaća dinamiku sezonskih kretanja, što predstavlja osjetljivu metodološku stavku na tržištu rada s izraženom turističkom komponentom. Ova se ograda najizravnije odnosi na interpretaciju razlika između priobalnih i kontinentalnih županija: s obzirom na to da podaci reflektiraju stanje u travnju, dio utvrđene varijacije može biti generiran sezonskim rasporedom prijavljivanja potreba, pa se taj specifični nalaz mora smatrati indikativnim dok se ne verificira kroz longitudinalni dizajn. Ipak, uočeni redoslijed intenziteta neusklađenosti po tipovima vještina znatno je manje osjetljiv na sezonske poremećaje, budući da počiva na uparenoj usporedbi unutar istih teritorijalnih jedinica gdje eksterni sezonski šokovi simultano pogađaju sve analizirane komponente.

Nadalje, primijenjena mjera utemeljena na Jaccardovu indeksu registrira isključivo binarnu prisutnost vještine unutar promatranog skupa, zanemarujući njezinu frekvenciju i razinu ovladanosti (intenzitet), što je čini neosjetljivom na dubinu potražnje. Osim toga, analitički moduli HZZ-a prikazuju rangirane popise najčešćih zanimanja i vještina, a ne potpun popis svih oznaka, pa su rjeđe vještine samo djelomično obuhvaćene. Analiza također obuhvaća devetnaest od dvadeset i jedne županije jer za dvije županije nisu raspoloživi podaci na ponudbenoj strani (potpoglavlje 3.1.). Naposljetku, institucionalni obuhvat analize ograničen je na registriranu nezaposlenost i prijavljena slobodna radna mjesta unutar HZZ-a, zbog čega izvan analitičkoga okvira ostaju neaktivne radno sposobne osobe, zaposlene

osobe koje traže promjenu posla te tokovi potražnje koji se ostvaruju izvan kanala javnoga posredovanja, primjerice putem privatnih portala, agencija za zapošljavanje, neposrednog zapošljavanja ili neformalnih mreža. Dobivene vrijednosti stoga treba tumačiti kao neusklađenost unutar segmenta tržišta rada koji posreduje HZZ, a ne kao potpunu mjeru neusklađenosti na cijelom hrvatskom tržištu rada.

Smjer moguće pristranosti nije moguće odrediti bez podataka o izostavljenim segmentima tržišta rada. Ako se radna mjesta koja se ne prijavljuju HZZ-u sustavno razlikuju po traženim vještinama, primjerice ako poslodavci za visokokvalificirana, digitalna ili deficitarna zanimanja češće koriste druge kanale zapošljavanja, potražnja za tim vještinama u analizi može biti podcijenjena ili drukčije strukturirana. Istodobno, registrirane nezaposlene osobe mogu imati drukčiji profil vještina od zaposlenih tražitelja posla i neaktivnih osoba, što utječe na izmjereno preklapanje ponudbene i potražne strane. Budući da je obuhvat jednak za sve županije i sve tipove vještina, to se ograničenje vjerojatno manje odražava na usporedbu među tipovima vještina, koja počiva na uparenim opažanjima, nego na apsolutnu razinu izmjerene neusklađenosti. Rezultati stoga pouzdano opisuju strukturu neusklađenosti u administrativno evidentiranom segmentu tržišta rada, ali ne omogućuju izravno zaključivanje o njezinu intenzitetu u ukupnoj populaciji radno sposobnih osoba i u svim kanalima zapošljavanja.

U tom smislu, buduća bi istraživanja trebala proširiti ovaj analitički model na više uzastopnih vremenskih intervala radi uspješne izolacije sezonske od trajne strukturne komponente neusklađenosti te integrirati ponderirane mjere intenziteta potražnje za pojedinim vještinama. Izrazito vrijedan smjer za nastavak istraživanja predstavljalo bi ekonometrijsko povezivanje ovako izmjerenih indeksa neusklađenosti s mikro-podacima o ishodima na tržištu rada za polaznike pojedinih programa prekvalifikacije, čime bi se omogućila rigorozna uzročna evaluacija njihove društveno-ekonomske učinkovitosti.

# DODATAK A. BROJ REGISTRIRANIH NEZAPOSLENIH OSOBA PO ŽUPANIJAMA

**Tablica A1. Broj registriranih nezaposlenih osoba po županijama i status u analizi, travanj 2026.**

| Županija | Registrirane nezaposlene osobe (n) | Status u analizi |
|---|---|---|
| Splitsko-dalmatinska | 10.745 | uključena |
| Grad Zagreb | 8.916 | uključena |
| Osječko-baranjska | 8.682 | uključena |
| Zagrebačka | 3.817 | uključena |
| Primorsko-goranska | 3.763 | uključena |
| Vukovarsko-srijemska | 3.677 | uključena |
| Sisačko-moslavačka | 3.293 | uključena |
| Dubrovačko-neretvanska | 2.710 | uključena |
| Zadarska | 2.446 | uključena |
| Šibensko-kninska | 2.440 | uključena |
| Virovitičko-podravska | 2.171 | uključena |
| Varaždinska | 1.708 | uključena |
| Bjelovarsko-bilogorska | 1.513 | uključena |
| Međimurska | 1.452 | uključena |
| Istarska | 1.399 | uključena |
| Karlovačka | 1.202 | uključena |
| Požeško-slavonska | 1.189 | uključena |
| Krapinsko-zagorska | 1.108 | uključena |
| Ličko-senjska | 737 | uključena |
| **Ukupno, 19 uključenih županija** | **62.968** | |

| Županija | Registrirane nezaposlene osobe (n) | Status u analizi |
|---|---|---|
| Brodsko-posavska | 3.587* | isključena |
| Koprivničko-križevačka | 966* | isključena |
| **Hrvatska ukupno** | **67.521** | |

Izvor: izračun autora prema administrativnim podacima Hrvatskoga zavoda za zapošljavanje (2026.), modul „Analize bazirane na vještinama" za registrirane nezaposlene osobe, redak „Ukupno". *Napomena:* *Modul ne sadržava podatke za Brodsko-posavsku i Koprivničko-križevačku županiju, pa je za njih broj registriranih nezaposlenih osoba preuzet iz Mjesečnoga statističkog biltena HZZ-a za travanj 2026. Ukupan broj prijavljenih potreba poslodavaca po županijama ne prikazuje se jer modul koji se odnosi na potražnju sadržava rangirane popise zanimanja i vještina bez ukupnoga broja potreba.

# LITERATURA

Bartolini, D. (2024). Addressing labor shortage in Croatia. U *Republic of Croatia: Selected issues* (IMF Country Report No. 2024/247). Washington: International Monetary Fund. Dostupno na https://www.elibrary.imf.org/view/journals/002/2024/247/article-A002-en.xml

Bečić, M. (2013). Obrazovna neusklađenost na tržištu rada: Preobrazovanost i njezine implikacije. *Ekonomski vjesnik, 26*(2), 621–636. Dostupno na https://hrcak.srce.hr/file/172174

Bečić, M. (2014). Preobrazovanost na tržištu rada Republike Hrvatske. *Ekonomska misao i praksa, 23*(1), 213–232. Dostupno na https://hrcak.srce.hr/file/185356

Bejaković, P. i Mrnjavac, Ž. (2014). Skill mismatches and anticipation of the future labour market need: Case of Croatia. *Privredna kretanja i ekonomska politika, 23*(2), 47–68. Dostupno na https://hrcak.srce.hr/120959

Cedefop (2010). *The skill matching challenge: Analysing skill mismatch and policy implications.* Luxembourg: Publications Office of the European Union. Dostupno na https://www.cedefop.europa.eu/files/9023_en.pdf

Cedefop (2020). *Strukovno obrazovanje i osposobljavanje u Hrvatskoj: Kratki pregled.* Luxembourg: Publications Office of the European Union. Dostupno na https://www.cedefop.europa.eu/files/4181_hr.pdf

Cedefop (2021). *Croatia: Mismatch priority occupations.* Dostupno na https://www.cedefop.europa.eu/en/data-insights/croatia-mismatch-priority-occupations

Cedefop (2024). *European Skills Index 2024: Technical report.* Dostupno na https://www.cedefop.europa.eu/files/esi_technical_report_2024.pdf

Duncan, O. D. i Duncan, B. (1955). A methodological analysis of segregation indexes. *American Sociological Review, 20*(2), 210–217. doi:10.2307/2088328

Europska komisija (2020). *Country report Croatia 2020* (SWD(2020) 510 final). Bruxelles: Europska komisija. Dostupno na https://vlada.gov.hr/UserDocsImages/00%20Foto%20mobitel/Europski%20semestar/Dokumenti%20i%20publikacije/SWD_2020_510_HR_DOCUMENTDETRAVAIL_f.pdf

Håkansson, P. G. i Bejaković, P. (2020). Labour market resilience, bottlenecks and spatial mobility in Croatia. *Eastern Journal of European Studies, 11*(2), 25–48. Dostupno na https://ejes.uaic.ro/articles/EJES2020_1102_HAK.pdf

Hrvatski zavod za zapošljavanje (2026). *Statistika On-Line: registrirana nezaposlenost i prijavljene potrebe poslodavaca* [baza podataka]. Dostupno na https://statistika.hzz.hr/

Jaccard, P. (1912). The distribution of the flora in the alpine zone. *New Phytologist, 11*(2), 37–50. doi:10.1111/j.1469-8137.1912.tb05611.x

McGuinness, S., Pouliakas, K. i Redmond, P. (2018). Skills mismatch: Concepts, measurement and policy approaches. *Journal of Economic Surveys, 32*(4), 985–1015. doi:10.1111/joes.12254

Obadić, A. i Viljevac, V. (2024). Occupational mismatch in the labour market of selected EU countries. Dostupno na https://hrcak.srce.hr/file/471334

Şahin, A., Song, J., Topa, G. i Violante, G. L. (2014). Mismatch unemployment. *American Economic Review, 104*(11), 3529–3564. doi:10.1257/aer.104.11.3529

Sala Lorda, G. (2011). Approaches to Skills Mismatch in the Labour Market: A Literature Review. *Revista de sociologia, 96*(4), 1025. doi:10.5565/rev/papers/v96n4.171

Tomić, I. (2014). Structural unemployment in Croatia: How important is the occupational mismatch? *Economic Research-Ekonomska Istraživanja, 27*(1), 346–365. Dostupno na https://hrcak.srce.hr/file/252799

Vlada Republike Hrvatske (2024). Odluka o razvrstavanju jedinica lokalne i područne (regionalne) samouprave prema stupnju razvijenosti. *Narodne novine*, br. 3/2024.

# SKILL MISMATCH IN THE CROATIAN LABOUR MARKET: AN ANALYSIS BY SKILL TYPE

***Abstract***

*The debate on skill mismatch in Croatia has so far been conducted mainly at the aggregate level, without a systematic comparison of skill types. The aim of the paper is to measure and compare mismatch in cross-sectoral (transversal), sectoral and occupation-specific skills. The analysis draws on administrative data of the Croatian Employment Service for April 2026 on employers' notified needs and registered unemployed persons, linked through a harmonised taxonomy based on the national classification of occupations and the Croatian Qualifications Framework. For nineteen counties, a mismatch measure based on the Jaccard coefficient (the Jaccard distance between the demanded and supplied skill sets) is computed. Horizontal occupational mismatch is measured by the Duncan index of dissimilarity, and the vertical dimension by the share of low-qualified persons (level 2 or below).*

*Mismatch is highest for sectoral skills (mean 80.2 %) and markedly lower for cross-sectoral (66.6 %) and occupation-specific (66.3 %) skills. Sectoral mismatch is significantly higher than that of the other two types, confirming the research hypothesis, whereas cross-sectoral and occupation-specific skills do not differ from each other. Sectoral mismatch exceeds 90 % in five counties and is highest in Zagrebačka county (97.3 %). The findings suggest that, within the administratively registered segment of the labour market, the largest divergence lies in sectoral skills, which supports considering sectorally and regionally targeted reskilling programmes designed in cooperation with employers. The analysis is cross-sectional and limited to the records of the Croatian Employment Service.*

***Keywords:*** *skill mismatch, skill types, sectoral skills, index of dissimilarity, Croatia.*

JEL klasifikacija: J1
Prethodno priopćenje

# STRANI RADNICI IZ AZIJSKIH ZEMALJA U REPUBLICI HRVATSKOJ: DIGITALNO-DEMOGRAFSKA ANALIZA MIGRACIJSKIH I INTEGRACIJSKIH OBRAZACA

Tado Jurić*

## SAŽETAK

Cilj rada jest ispitati može li LinkedIn, kao izvor digitalnih tragova, dopuniti službene administrativne izvore u analizi radnih migracija i ranih pokazatelja integracije stranih radnika u Hrvatskoj. Istraživanje obuhvaća radnike iz Filipina, Indije, Nepala i Bangladeša, s naglaskom na višefazne migracije i prethodni boravak u državama Zaljeva.

Istraživanje primjenjuje pristup digitalne demografije na korpusu od 81 javno dostupnog LinkedIn profila, uz triangulaciju digitalnih tragova s administrativnim podacima MUP-a, HZMO-a i HZZ-a. Doprinos rada je dvojak. Prvo, rad sustavno dokumentira nepodudarnosti između administrativnih evidencija MUP-a, HZMO-a i HZZ-a te statističkih evidencija DZS-a i pokazuje da je riječ o sustavnoj metodološkoj razlici, a ne o pogrešci pojedinog izvora. Drugo, analiza korpusa od 81 profila prepoznaje obrasce

* Izv. prof. dr. sc. Tado Jurić, Hrvatsko katoličko sveučilište (e-mail: tado.juric@unicath.hr).

višefazne migracije preko država Zaljeva, sektorske koncentracije po nacionalnim skupinama te pojave profesionalnog snižavanja kvalifikacija (deskillinga). Kod 26 profila (32,1 % korpusa) vidljiv je prethodni boravak u državama Zaljeva.

Ograničenje istraživanja proizlazi iz selektivnosti LinkedIna, čiji javno dostupni profili predstavljaju samoselektiran i profesionalno usmjeren dio populacije stranih radnika te nisu reprezentativni za njezinu ukupnu strukturu. Originalnost rada proizlazi iz primjene digitalne demografije i LinkedIna na proučavanje radnih migracija u Hrvatskoj te povezivanja digitalnih profesionalnih tragova sa službenim administrativnim izvorima. Rezultati pokazuju da digitalni tragovi mogu biti vrijedan dopunski izvor za prepoznavanje migracijskih i profesionalnih obrazaca koji nisu u potpunosti vidljivi u službenoj statistici.

**Ključne riječi:** strani radnici, digitalna demografija, LinkedIn, integracija, migracije.

## 1. UVOD

Posljednje desetljeće obilježila je izrazita promjena migracijskog položaja Hrvatske. Nakon razdoblja u kojem su migracijski procesi bili pretežito obilježeni iseljavanjem hrvatskih državljana, Hrvatska se u relativno kratkom vremenu transformirala u zemlju intenzivne radne imigracije. Liberalizacija zapošljavanja stranih radnika, nedostatak domaće radne snage i rast gospodarstva doveli su do naglog povećanja broja radnika iz trećih zemalja, osobito iz Filipina, Indije, Nepala i Bangladeša. Hrvatska je time ušla u novu fazu migracijskog ciklusa, karakterističnu za države koje iz emigracijskih postupno postaju imigracijske zemlje, pri čemu razvoj institucionalnih kapaciteta za upravljanje migracijama često zaostaje za intenzitetom migracijskih tokova (Castles, 2010; Kraler i sur., 2010; Jurić, 2025).

Takva transformacija otvorila je nova znanstvena i metodološka pitanja. Hrvatska raspolaže velikim brojem administrativnih podataka o stranim radnicima, ali oni proizlaze iz različitih sustava i služe različitim institucionalnim svrhama. Ministarstvo unutarnjih poslova evidentira izdane dozvole za boravak i rad, Hrvatski zavod za mirovinsko osiguranje registrira osiguranike uključene u sustav obveznog osiguranja, Hrvatski zavod za zapošljavanje vodi evidencije iz svoje nadležnosti, dok Državni zavod za statistiku primjenjuje međunarodne statističke definicije migranata. Budući

da te institucije ne mjere isti fenomen, među njihovim podacima pojavljuju se razlike koje otežavaju procjenu opsega imigracije, trajanja boravka stranih radnika i njihove integracije na hrvatskom tržištu rada. Temeljni metodološki problem stoga nije nužno vjerodostojnost pojedinog izvora, nego činjenica da postojeći administrativni sustavi nisu razvijeni za cjelovito praćenje suvremenih migracijskih procesa (Kraler i sur., 2010; DZS, 2023; Jurić, 2025).

Slični problemi prepoznati su i u međunarodnoj migracijskoj literaturi. Intenziviranje međunarodne mobilnosti, razvoj transnacionalnih migracijskih mreža i sve dinamičniji obrasci cirkularnih i višefaznih migracija otežavaju pravodobno registriranje migracijskih procesa u tradicionalnim statističkim sustavima (Castles, 2010). Zbog toga raste interes za nove izvore podataka koji mogu nadopuniti službene statistike. Digitalna demografija predstavlja jedan od takvih metodoloških pristupa. Digitalni tragovi nastali korištenjem internetskih platformi mogu pružiti informacije koje klasične administrativne i statističke evidencije često ne sadrže (Kitchin, 2014; Cesare i sur., 2018; Graham i Dutton, 2019). Dosadašnja istraživanja pokazala su mogućnost njihove primjene u proučavanju migracijskih namjera, međunarodne mobilnosti, profesionalnih karijera i procesa integracije migranata (Kim i sur., 2020; Jurić, 2022; Jurić, 2023).

Posebno mjesto među digitalnim izvorima zauzima LinkedIn jer profesionalni profili sadrže podatke o obrazovanju, radnom iskustvu, sektorima zaposlenja, promjenama poslodavaca i međunarodnoj profesionalnoj mobilnosti. Zbog tih obilježja LinkedIn je korišten u istraživanjima radnih migracija, profesionalne mobilnosti, akademske mobilnosti i međunarodnog kretanja visokokvalificiranih radnika (Cesare i sur., 2018; Coimbra Vieira i sur., 2022). Međutim, upravo profesionalna usmjerenost platforme ograničava mogućnost njezina korištenja kao reprezentativnog izvora za ukupnu populaciju stranih radnika. Mogućnosti primjene LinkedIna u proučavanju nisko i srednje kvalificiranih radnih migracija te organiziranog zapošljavanja stranih radnika u zemljama koje tek ulaze u imigracijski ciklus stoga ostaju slabije istražene.

To posebno vrijedi za Hrvatsku. Dosadašnja domaća istraživanja stranih radnika pretežito su se oslanjala na administrativne izvore, anketna istraživanja ili kvalitativne intervjue (Butković i sur., 2022; Jurić, 2024; IMIN, 2025). Istodobno je digitalna demografija već primijenjena u istraživanju iseljavanja iz Hrvatske i međunarodnih migracijskih tokova

(Jurić, 2022; 2023), ali LinkedIn dosad nije sustavno korišten kao primarni empirijski izvor za analizu migracijskih tokova stranih radnika u Hrvatskoj. Time ostaje otvoreno pitanje mogu li digitalni tragovi pružiti dodatne informacije o migracijskim putanjama, profesionalnim obrascima i ranim pokazateljima integracije.

Polazeći od toga istraživačkog jaza, cilj rada jest ispitati može li LinkedIn, kao izvor digitalnih tragova, dopuniti službene administrativne izvore u analizi radnih migracija i ranih pokazatelja integracije stranih radnika u Hrvatskoj. Istraživanje se usmjerava na radnike iz Filipina, Indije, Nepala i Bangladeša. Istraživačka pitanja:

1. Koje se metodološke nepodudarnosti pojavljuju između administrativnih i statističkih evidencija o stranim radnicima u Hrvatskoj i kako utječu na procjenu opsega radne imigracije?
2. Koji se obrasci višefazne migracije i sektorske koncentracije mogu identificirati u digitalnom korpusu[1] stranih radnika iz Nepala, Indije, Bangladeša i Filipina?
3. Koji se obrasci profesionalne mobilnosti (integracija), uključujući profesionalno snižavanje kvalifikacija (deskilling) i platformski rad, mogu prepoznati na temelju javno dostupnih LinkedIn profila?

## 2. VJERODOSTOJNOST SLUŽBENIH PODATAKA O STRANIM RADNICIMA U HRVATSKOJ

Budući da je Hrvatska 2021. ukinula kvotni sustav za zapošljavanje stranih radnika i prešla na model uvoza radne snage temeljen na potrebama poslodavaca, došlo je do naglog povećanja useljavanja koje institucionalni sustav nije u cijelosti pratio. Već 2022. broj izdanih dozvola porastao je za više od 55 % u odnosu na 2019. i 2020. godinu, čime su dodatno došla do izražaja ograničenja postojećeg sustava evidentiranja međunarodnih migracija i stranih radnika. Liberalizacija ulaska tako nije bila praćena jedinstvenim sustavom praćenja, što je povećalo razlike između administrativnih i statističkih evidencija.

[1] Digitalni korpus, odnosno prigodno prikupljena zbirka javno dostupnih profila koja ne predstavlja uzorak u statističkom smislu.

Za razliku od ranijih razdoblja, kada su dio demografskih gubitaka nadomještali etnički Hrvati iz BiH, noviji migracijski tokovi donose veći udio vidljivih imigracijskih skupina izvan europskog prostora. Među najbrže rastućim skupinama nalaze se radnici iz Nepala, Indije, Bangladeša i Filipina. Važno je pritom naglasiti da radnici iz Azije čine oko polovicu svih useljenih stranih radnika iz trećih zemalja, dok drugu polovicu čine radnici iz Jugoistočne Europe (Jurić, 2025).

Službene brojke DZS-a pokazuju snažan rast useljavanja: od približno 36.000 novih useljenika iz trećih zemalja 2021., preko 58.000 u 2022., do više od 70.000 u 2023. godini (Jurić, 2025: 230). Međutim, usporedba pojedinih evidencija pokazuje znatne razlike u obuhvatu, koje proizlaze iz različitih kriterija evidentiranja međunarodnih useljenika i izdanih administrativnih dozvola. Hrvatska stoga raspolaže većim brojem administrativnih evidencija, ali nema jedinstvenu evidenciju kojom bi se mogao precizno utvrditi stvarni opseg radne imigracije[2] i njezino trajanje.

Dodatni problem predstavljaju razlike među podacima službenih institucija. Prema Anketi o radnoj snazi (2021), broj stranaca zaposlenih u Hrvatskoj 2020. godine iznosio je oko 10.000, dok ih je HZMO registrirao više od 87.000. Ministarstvo rada navodi 172.499 izdanih radnih i boravišnih dozvola u 2023. godini (Jurić, 2025: 229), dok Hrvatska narodna banka procjenjuje da broj stranih radnika u 2022. nije dosezao 50.000 (Banić i sur., 2024). Prema Jurićevoj analizi (2023), odstupanja između podataka MUP-a i DZS-a o broju stranih radnika iznosila su 16,17 % za 2018., 43,54 % za 2019., 36,64 % za 2020. te 47,11 % za 2022. godinu (DZS, 2023).

Hrvatska je u razdoblju 2019. – 2025. izdala više od 700.000 dozvola za rad stranim radnicima iz trećih zemalja (vidi fusnotu 2). Usporedba registara MUP-a, HZZ-a, HZMO-a i DZS-a pokazuje da se broj evidentiranih osoba i broj izdanih dozvola ne mogu izjednačiti. Razlike proizlaze, među ostalim, iz činjenice da jedan radnik može tijekom godine dobiti više dozvola, primjerice zbog promjene poslodavca, ali i iz različitog vremenskog i sadržajnog

[2] Relativni demografski učinak priljeva stranih radnika potrebno je promatrati u odnosu na veličinu ukupne populacije države. Tako priljev od približno 80.000 stranih radnika u jednoj godini, kao što je zabilježeno 2019., odnosno približno 170.000 u 2023., ima znatno veći relativni učinak na demografsku strukturu Hrvatske nego priljev apsolutno većeg broja useljenika u demografski znatno većim državama, poput Njemačke. Stoga se intenzitet migracijskog priljeva ne može primjereno procjenjivati samo na temelju apsolutnih pokazatelja nego i u odnosu na veličinu populacije zemlje odredišta (Jurić, 2025).

obuhvata pojedinih evidencija. Stoga navedene podatke treba interpretirati kao različite administrativne pokazatelje migracijskog procesa, a ne kao međusobno zamjenjive procjene broja osoba.[3] Razlike između službenih registara iznose i do 40 do 50 %.

**Tablica 1. Broj izdanih dozvola za boravak i rad, MUP (2019. – 2025.)**

| Godina | Broj izdanih dozvola za boravak i rad | Novo zapošljavanje | Produljenje | Sezonske dozvole |
|---|---|---|---|---|
| **2019.** | 72.523 | nepoznato | nepoznato | nepoznato |
| **2020.** | 66.655 | nepoznato | nepoznato | nepoznato |
| **2021.** | 81.995 | nepoznato | nepoznato | nepoznato |
| **2022.** | 124.121 | nepoznato | nepoznato | nepoznato |
| **2023.** | **172.499** | **112.981** | **40.660** | **18.858** |
| **2024.** | **206.529** | **132.208** | **56.898** | **17.423** |
| **2025.** | **170.723** | **80.365** | **70.275** | **20.083** |

Izvor: autor prema podacima MUP-a (2025; 2026).

* Napomena 1.: "Novo zapošljavanje", "Produljenje", "Sezonske dozvole" su kategorije iz izvještaja MUP-a za 2023., 2024. i 2025. – za starije godine te kategorije nisu sistematski dostupne.

Iz Tablice 1. vidljivo je da se broj izdanih dozvola za boravak i rad između 2019. i 2024. gotovo utrostručio. Nakon 2023. moguće je razlikovati dozvole za novo zapošljavanje, produljenja i sezonski rad, što omogućuje precizniju analizu strukture useljavanja i usporedbu sa službenom migracijskom statistikom. Istodobno, podaci pokazuju rast udjela produljenja, što može upućivati na postupni prijelaz dijela stranih radnika iz faze prvog dolaska prema duljem boravku u Hrvatskoj. Sama evidencija izdanih dozvola, međutim, ne može pokazati koliko stranih radnika u određenom trenutku stvarno živi i radi u Hrvatskoj.

[3] Koncem 2023. u Hrvatskoj je bilo 117.549 stranih državljana s važećim dozvolama za boravak i rad, dok je HZMO bilježio samo 90.000 prijavljenih osiguranika (Grgas, 2024). Otprilike 30.000 nositelja važećih radnih dozvola dakle nije postojalo u sustavu socijalnih doprinosa. MUP tu razliku objašnjava na način da broj izdanih dozvola ne odgovara broju radnika jer jedan radnik može dobiti više dozvola tijekom godine uslijed promjena poslodavca. Ovaj diskrepantni raspon otvara nekoliko pitanja: dio radnika možda nikada nije došao u Hrvatsku, dio je otišao dalje u druge članice EU-a, a dio radi u sivoj ekonomiji bez prijave.

Podaci MUP-a stoga se moraju usporediti sa statistikom međunarodnih useljenika DZS-a. Izdana dozvola nije isto što i međunarodni useljenik u statističkom smislu, jer DZS međunarodne useljenike evidentira prema definiciji uobičajenog mjesta stanovanja. Takva usporedba omogućuje procjenu razmjera nepodudarnosti između administrativnih i statističkih evidencija.

**Tablica 2. Usporedba administrativnih podataka MUP-a i statistike međunarodnih useljenika DZS-a (2023. – 2025.)**

| Godina | MUP – ukupno dozvola | MUP – novo zapošljavanje | DZS – međunarodni useljenici (strani državljani) | Razlika (ukupno – DZS) | Razlika (novo zapošljavanje – DZS) |
|---|---|---|---|---|---|
| **2023.** | 172.499 | 112.981 | 69.396 | 103.103 | **43.585** |
| **2024.** | 206.529 | 132.208 | 70.391 | 136.138 | **61.817** |
| **2025.** | 170.723 | 80.365 | 56.665 | 114.058 | **23.700** |

Izvor: autor prema podacima DZS (2026) i MUP (2026).

Tablica 2. pokazuje da se razlike između administrativnih i statističkih evidencija ne mogu objasniti samo činjenicom da ukupan broj izdanih dozvola uključuje produljenja i sezonski rad. Čak i kada se uzmu u obzir isključivo dozvole izdane za novo zapošljavanje, broj novih radnih dozvola i dalje je veći od broja međunarodnih useljenika koje evidentira DZS. Razlika iznosi 43.585 u 2023., 61.817 u 2024. te 23.700 u 2025. godini. Budući da se obrazac ponavlja tijekom više godina, riječ je o sustavnoj metodološkoj razlici između administrativnog i statističkog sustava evidentiranja. Dobiveni rezultati potvrđuju da administrativni i statistički izvori ne mjere istu populaciju te ih nije moguće izravno uspoređivati bez uvažavanja njihove metodologije.

Koncem 2023. u Hrvatskoj je bilo 117.549 stranih državljana s važećim dozvolama za boravak i rad, dok je HZMO bilježio samo oko 90.000 prijavljenih osiguranika (Grgas, 2024). Razlika od približno 30.000 osoba ne znači nužno da te osobe nisu bile prisutne u Hrvatskoj, jer, kako već spomenuto, jedan radnik može tijekom godine dobiti više dozvola. Ipak, diskrepancije među evidencijama pokazuju ograničenja pojedinačnih administrativnih izvora u procjeni stvarnog opsega i strukture radne imigracije.

Opisane nepodudarnosti između službenih evidencija upućuju na potrebu razvoja integriranog sustava praćenja međunarodnih migracija koji bi omogućio pouzdanije procjene broja stranih radnika i njihovih demografskih obilježja. To predstavlja važan preduvjet za oblikovanje migracijskih, tržišnih i integracijskih politika u Hrvatskoj. Istodobno je broj znanstvenih istraživanja koja se bave metodološkim i demografskim aspektima novog useljavanja u Hrvatskoj još uvijek vrlo ograničen (Butković i sur., 2022; Balabanić i sur., 2025; Jurić, 2023; 2024; 2025). Istodobno, rezultati istraživanja digitalnih tragova upućuju na to da migraciju nije moguće promatrati samo kao epizodni dolazak radne snage nego i kao proces u kojem se razvijaju trajnije migrantske zajednice (Jurić, 2025).

## 2.1. Umrežene migracije: Hrvatska kao redistributivna faza globalnog lanca rada

Hrvatski slučaj potvrđuje opće upozorenje migracijske literature o „perifernoj migracijskoj dinamici“: države koje kasno ulaze u imigracijski ciklus mogu to učiniti brzo, bez odgovarajuće pripreme i uz visoku razinu netransparentnosti, čime nastaju uvjeti za prekarizirane migrantske ekonomije, paralelne sustave i institucionalne slijepe točke (usp. Castles, 2010; Kraler i sur. 2010).

Jedan dio stranih radnika iz Azije u Hrvatskoj prethodno je radio u državama Zaljeva – Katru, Saudijskoj Arabiji i Ujedinjenim Arapskim Emiratima (vidi empirijski dio rada) – gdje sustav „kafale“[4] onemogućuje trajni boravak i proizvodi „višefazne migracije“ koje se preusmjeravaju prema potrebama kapitala (Gardner, 2011; Hossain, 2018). U takav model Hrvatska ulazi nakon (prije spomenutog) masovnog iseljavanja domaće radne snage čime se otvorio prostor za intenzivan uvoz stranih radnika.

Istodobno s otvaranjem hrvatskog tržišta rada prema trećim zemljama razvija se institucionalna infrastruktura migracijskih tokova, osobito mreža posredničkih agencija za zapošljavanje stranih radnika. U Hrvatskoj je 2025. registrirano 712 takvih agencija (MROSP.hr), što upućuje na razvoj opsežne infrastrukture međunarodnog posredovanja. Takva infrastruktura predstavlja važan element suvremenih transnacionalnih migracijskih mreža (Wickramasekara, 2016). Hrvatske agencije povezuju se s agentima u Dohi,

[4] Arapska riječ koja označava sponzorstvo.

Dubaju i drugim centrima država Zaljeva, gdje već desetljećima postoje stabilni regrutacijski kanali za azijsku radnu snagu. Time hrvatske agencije postaju lokalni distributivni čvorovi unutar globalnih lanaca rada (Wickramasekara, 2016).

Ta umreženost može objasniti pojavu sinkroniziranih valova radnika iz Azije u Hrvatskoj. U gotovo istim razdobljima različite skupine dolaze u sektore u kojima postoji potražnja: Nepalci u logistiku i čišćenje, Bangladešani u pekarstvo i prehrambenu industriju, Filipinci u skladišta i trgovinu, a Indijci u dostavne platforme (vidi empirijski dio). Vremenska i sektorska pravilnost tih tokova upućuje na važnost kolektivno posredovane migracije i transnacionalnih regrutacijskih mreža. U Hrvatsku strani radnici stoga ne dolaze isključivo individualnim migracijskim odlukama, nego organizirano (Siddiqui, 2003; Gardner, 2011).

Regrutacijske mreže utječu na to kada i prema kojoj se zemlji radnici kreću. Države Zaljeva u tom modelu predstavljaju „prvu fazu“ (Gardner, 2011; Hossain, 2018), dok se Hrvatska pojavljuje kao druga faza. Europski pravni okvir omogućuje duži boravak, manje restriktivne uvjete rada i mogućnost stjecanja stalnog boravka nakon pet godina. Nakon te faze migracijske se putanje mogu razvijati u dva smjera. Prvi je stabilizacija u Hrvatskoj, nastavak rada i, nakon stjecanja uvjeta, obiteljsko spajanje. Upravo mogućnost dugoročnijeg boravka i obiteljskog spajanja predstavlja važan privlačni faktor koji u državama Zaljeva uglavnom nije dostupan na isti način. Drugi je daljnja mobilnost prema ekonomski snažnijim državama Europske unije.

U skladu s modelom višefazne migracije (Gardner, 2011; Hossain, 2018), Hrvatska u pojedinim slučajevima može predstavljati tranzicijsku fazu prema razvijenijim tržištima rada, poput Njemačke, Austrije ili Irske, gdje su plaće više, socijalni sustavi sigurniji, a potražnja za radnicima u određenim sektorima izraženija. Takva mobilnost ipak nije automatska jer navedene države primjenjuju selekcijske sustave koji zahtijevaju formalno poznavanje jezika, verificirane kvalifikacije i često prethodno iskustvo u reguliranim sektorima. Budući da se u Hrvatskoj značajan dio migranata zapošljava u niskokvalificiranim zanimanjima i ne uči sustavno hrvatski jezik, ne stječu nužno kompetencije potrebne za prolazak kroz visoke selekcijske pragove Njemačke (chancenkarte.com), Austrije („Rot-Weiß-Rot Karte“) ili Irske.

Na temelju analiziranih migracijskih obrazaca može se pretpostaviti da će dio radnika nakon stjecanja uvjeta za stalni boravak ostati u Hrvatskoj i koristiti

mogućnost spajanja obitelji, dok će dio nastaviti migraciju prema drugim državama članicama Europske unije. To pitanje, međutim, nadilazi empirijski okvir ovoga rada i zahtijeva longitudinalna istraživanja. Manji dio radnika može ući i u treću fazu cirkulacije, odnosno vratiti se u zemlju podrijetla ili ponovno migrirati prema drugim destinacijama, što je dokumentiran obrazac u literaturi o južnoazijskim migracijama (Siddiqui, 2003; Rahman, 2012).

– Teorijski dio rada –

## 3. DIGITALNA DEMOGRAFIJA KAO NOVI METODOLOŠKI OKVIR ISTRAŽIVANJA MIGRACIJA: MOGUĆNOSTI, GRANICE I PRIMJENA U HRVATSKOJ

Digitalna demografija predstavlja interdisciplinarni istraživački pristup koji koristi digitalne tragove nastale uporabom internetskih platformi za analizu demografskih procesa i migracijskih obrazaca. Njezin razvoj potaknut je sve većom dostupnošću podataka koje korisnici ostavljaju tijekom svakodnevnih aktivnosti na digitalnim platformama. Takvi izvori, od internetskih pretraživanja i društvenih mreža do profesionalnih profila na LinkedInu, omogućuju pravodobniji uvid u obrasce ponašanja, mobilnosti i profesionalnih kretanja te nadopunjuju spoznaje koje tradicionalni statistički sustavi često ne mogu pružiti (Alexander i sur., 2020; Jurić, 2023; Kim i sur., 2020).

U migracijskoj literaturi digitalni tragovi prepoznati su kao važan metodološki iskorak jer omogućuju analizu ne samo agregatnih demografskih promjena nego i mikroobrazaca ponašanja koji im prethode. Europska komisija i Ujedinjeni narodi u svojim su izvješćima naglasili da „big data“ pristup ne može zamijeniti službenu statistiku, ali može poboljšati njezinu preciznost i omogućiti ranije prepoznavanje demografskih trendova (Spyratos i sur., 2018). Njegova je prednost i u dostupnosti podataka te mogućnosti smanjenja nekih pristranosti tradicionalnih anketa, poput davanja društveno poželjnih odgovora na osjetljive teme (Cesare i sur., 2018).

U kontekstu Hrvatske, testiranje različitih „big data“ pristupa pokazalo je da je LinkedIn osobito vrijedan izvor za analizu radnih migracija i profesionalne integracije. Profesionalni profili sadrže podatke o kvalifikacijama, radnim putanjama i prethodnim migracijskim iskustvima koji nisu sustavno dostupni u hrvatskim statističkim evidencijama. Digitalna demografija stoga u ovom

radu nije samo metodološki okvir nego i alat za razumijevanje pojedinih dimenzija demografske transformacije hrvatskog društva.

## 3.1. LinkedIn kao izvor analitičkih uvida u migracijske obrasce – pregled literature

U Hrvatskoj, ali i šire na prostoru jugoistočne Europe, korištenje LinkedIna kao istraživačkog pristupa još je uvijek rijetko i metodološki nedovoljno razvijeno. Međunarodna literatura, međutim, pokazuje da LinkedIn može biti vrijedan izvor za istraživanja mobilnosti i radnih migracija. Coimbra Vieira i sur. (2022) ističu da LinkedIn omogućuje uvid u „bazu digitalnih tragova" koja omogućuje praćenje profesionalnih i migracijskih kretanja, osobito tamo gdje službene statistike kasne ili su fragmentirane. Cesare i sur. (2018) dodatno ističu da digitalni profesionalni profili omogućuju rekonstrukciju radnih putanja i identifikaciju globalnih lanaca rada koji nisu vidljivi tradicionalnim metodama.

U SAD-u LinkedIn je postao važan alat za analizu regionalnih tržišta rada kroz projekt LinkedIn Economic Graph (economicgraph.com). Na europskoj razini LinkedIn je korišten za analizu međunarodne mobilnosti visokokvalificiranih stručnjaka i migracijskih aspiracija profesionalaca (Perrotta i sur., 2022). Međunarodna iskustva stoga potvrđuju njegovu uporabnu vrijednost kao sekundarnog izvora za proučavanje radnih migracija. U Hrvatskoj takva istraživačka praksa još nije zaživjela. Ne postoji javno dostupan znanstveni rad koji LinkedIn koristi kao primarni empirijski izvor za analizu migracijskih procesa. Ova je praznina zapažena i u pregledima tzv. Big Data pristupa u hrvatskoj znanosti (Jurić, 2023).

## 3.2. Metodologija, pristup i ograničenja

U ovom istraživanju LinkedIn je korišten kao sekundarni digitalni izvor podataka za analizu radnih migracija radnika iz Filipina, Indije, Nepala i Bangladeša u Hrvatskoj. Platforma omogućuje uvid u javno dostupne podatke koje korisnici sami unose, uključujući obrazovanje, prethodna radna mjesta, trenutno prebivalište i sektor zaposlenja.

Istraživanje je provedeno u prosincu 2025. U analizu su uključeni isključivo profili kod kojih ni uz potencijalnu rekonstrukciju nije moguće razotkriti

identitet pojedinca. Zbog toga su radna mjesta unutar manjih poduzeća, gdje je rizik identifikacije veći, izostavljena iz ilustrativnog izbora profila prikazanog u analitičkim tablicama. Podaci su prikazani agregirano, dok je za svaku useljeničku skupinu iz Azije izdvojeno po pet primjera prikazanih u četiri analitičke tablice.

Ukupni digitalni korpus obuhvaća 81 javno dostupan profil: 23 profila radnika iz Nepala, 26 iz Indije, 18 iz Bangladeša i 14 iz Filipina. U korpusu je oko 85 % muškaraca, dok je kod 26 profila vidljiv prethodni boravak u državama Zaljeva. Iz ukupnog korpusa je 20 profila prikazano kao ilustrativni izbor. 85 % analiziranih profila čine muškarci. Kod 26 profila jasno je vidljiv obrazac višefazne migracije, odnosno prethodna migracija iz Azije u države Zaljeva, nakon koje slijedi dolazak u Hrvatsku.

Osim sektorske analize klasičnih zaposlenja, analizirani su i digitalni tragovi tzv. platformskog rada (gig-ekonomija). U tu svrhu detaljnije su analizirana 33 profila koji čine podskup unutar ukupnoga digitalnog korpusa od 81 profila. Riječ je o profilima koji, uz podrijetlo iz Nepala, Indije, Bangladeša ili Filipina, pokazuju povezanost s platformskim radom u Hrvatskoj, uključujući Wolt, Bolt, Uber i Glovo. Nalazi za ovaj podskup koriste se u radu za dopunu analize profesionalne mobilnosti i ne predstavljaju zaseban korpus.

Ovaj se pristup pokazuje osobito korisnim zbog jedne od ključnih prepreka u istraživanju azijskih radnika u Hrvatskoj: izraženog straha od sudjelovanja u intervjuima (Gardner, 2011; Rahman, 2012; Hossain, 2018). Ta se dinamika ne mijenja bitno ni po dolasku u Europu jer se modeli opreza i samodiscipline mogu prenositi iz prethodnih migracijskih faza. Korištenje LinkedIna omogućuje analizu javno objavljenih profesionalnih informacija bez izravne interakcije s ispitanikom, čime se smanjuje mogućnost da istraživački postupak kod pojedinca izazove osjećaj rizika, nelagode ili straha.[5]

Metodološki postupak rada s LinkedInom započinje kombiniranjem filtera zemlje podrijetla i lokacije, primjerice „Nepal Zagreb“, „India Croatia“ ili „Filipino Croatia“. Time LinkedIn prikazuje korisnike koji u profilu navode boravak u Hrvatskoj. Već u toj fazi mogu se identificirati osnovni obrasci, uključujući zanimanje, poslodavca, obrazovne institucije i godinu početka rada u Hrvatskoj, što omogućuje rekonstrukciju pojedinih migracijskih putanja.

[5] Dodatno, radnici na LinkedInu uglavnom prikazuju svoje radne putanje s ponosom, kao izraz profesionalnog identiteta.

Dodatnu analitičku preciznost omogućuju filteri za lokaciju (Croatia, Zagreb), trenutnu i prijašnju tvrtku, obrazovanje te jezike. Pokazalo se da je filter „School" uz dodatak zemlje podrijetla, primjerice „School: India", najprecizniji alat za identifikaciju radnika iz Indije. Slično, kombinacija jezika (Hindi, Nepali, Bengali, Urdu, Filipino) i poslodavaca, primjerice u logistici, IT-u i trgovini, omogućuje identifikaciju sektorskih koncentracija. LinkedIn omogućuje i pretraživanje kompanijskih stranica poput „Uber Croatia", „Bolt Croatia", „Wolt Croatia" i „Glovo Croatia" te njihovih lista zaposlenih.

U okviru ovog istraživanja primijenjen je postupak identifikacije stranih radnika koji se temelji na kombinaciji lokacije i obrazovanja. Pilot-testiranje pokazalo je da je metodološki najprecizniji postupak kombinirati lokaciju Hrvatska/Zagreb s filterom „School" i zemljom obrazovanja, primjerice India, Nepal, Philippines ili Bangladesh. Na taj se način mogu identificirati korisnici koji su završili obrazovne institucije u navedenim državama, neovisno o tome jesu li u profilu izričito naveli nacionalnost. Pri testiranju se ovaj postupak pokazao preciznijim od pretrage prema jeziku ili zanimanju.

Iz profila korisnika moguće je iščitati i migracijske rute, primjerice prethodni rad u Nepalu i Kataru prije dolaska u Hrvatsku ili iskustvo rada u Indiji i Ujedinjenim Arapskim Emiratima prije dolaska u Hrvatsku, što potvrđuje prisutnost sekundarne migracije opisane u literaturi o posredovanim radnim migracijama (Gardner, 2011; Hossain, 2018; Wickramasekara, 2016). Posebno je vrijedna godina početka rada u Hrvatskoj jer omogućuje rekonstrukciju dinamike dolazaka i približnog trajanja boravka u zemlji.

Važno je istaknuti i etičke aspekte digitalne detekcije i rada s platformskim podacima (Big Data). U skladu s preporukama za korištenje digitalnih tragova u migracijskim istraživanjima (Kitchin, 2014; Graham i Dutton, 2019), analiza se provodila isključivo na javno dostupnim, samostalno objavljenim profesionalnim informacijama.[6] Niti jedan podatak ne preuzima se u osobnom ili identifikacijskom obliku; profili se tretiraju anonimno, a rezultati prikazuju isključivo na agregiranoj razini. Time se osigurava poštivanje privatnosti i istraživačke etike uz zadržavanje analitičke vrijednosti.[7] Unatoč tome, ostaju

[6] Istraživanje je izrađeno u skladu s etičkim kodeksom HKS-a i prijavljeno je Etičkom povjerenstvu HKS-a.

[7] Korišteni „instrument" je analitički protokol za prikupljanje i sistematizaciju javno dostupnih profesionalnih podataka. Svi podaci su odmah anonimizirani i agregirani.

otvorena etička pitanja jer korisnici nisu eksplicitno obaviješteni o mogućnosti da njihovi profili budu korišteni u istraživačke svrhe (vidi Jurić, 2022).[8]

Važno je napomenuti i metodološka ograničenja. Nisu svi profili javni, niti svi radnici koriste LinkedIn, što znači da se analiza temelji na djelomičnom i samo-selektiranom skupu korisnika, obilježju karakterističnom za digitalne izvore (Cesare i sur., 2018). Ipak, čak i kada su profili djelomično vidljivi, moguće je prepoznati ključne indikatore poput zanimanja, sektora rada ili godine dolaska u Hrvatsku.

Posebno je važno uzeti u obzir selektivnost LinkedIna kao izvora podataka. Platforma je profesionalno usmjerena na viši stupanj obrazovanja, a njezini su korisnici u prosjeku obrazovaniji od populacije strane radne snage u Hrvatskoj, pri čemu su određena profesionalna i sektorska područja nerazmjerno zastupljena. Istraživanja digitalne demografije stoga upozoravaju da LinkedIn podaci nisu reprezentativni za ukupnu populaciju te da su osobito prikladni za proučavanje profesionalne i visokokvalificirane mobilnosti (Cesare i sur., 2018). U kontekstu Hrvatske to je ograničenje posebno važno jer značajan dio novijih radnih migracija čine radnici u nisko i srednje kvalificiranim zanimanjima. Posljedično, korpus od N = 81 profila ne može se interpretirati kao reprezentativan presjek stranih radnika u Hrvatskoj, nego kao selektivni digitalni korpus koji omogućuje identifikaciju određenih migracijskih i profesionalnih obrazaca.

Metodološka vrijednost ovoga pristupa stoga nije u procjeni ukupnog broja stranih radnika, nego u identifikaciji migracijskih obrazaca, profesionalnih putanja i ranih pokazatelja integracije koji ostaju djelomično nevidljivi u administrativnim evidencijama. Dobivene rezultate treba promatrati kao dopunu administrativnim izvorima, a ne kao njihovu zamjenu. Nakon prikaza metodološkog postupka u nastavku slijedi njegova empirijska primjena.

[8] Dio analitičkih mogućnosti može se koristiti samo uz LinkedIn Premium. Ipak, javno vidljivi podaci dovoljni za identifikaciju migracijskih putanja, sektorske koncentracije i obrazaca platformskog rada.

– Empirijski dio rada –

# 4. ANALIZA LINKEDIN PODATAKA O IMIGRACIJI U HRVATSKU

Uvodno prikazana situacija, u kojoj država istodobno omogućuje masovni uvoz radne snage, ali ne zna koliko tih radnika uistinu boravi i radi na njezinu teritoriju, proizvodi temeljnu metodološku napetost. Istraživač proučava populaciju za koju javne institucije znaju da postoji, ali je ne uspijevaju „vidjeti“, kvantificirati ni razumjeti. Hrvatski se slučaj time uklapa u ono što Cesare i sur. (2018) nazivaju „demografijom nevidljivih populacija“. Demografska analiza stoga mora djelovati u uvjetima slabe evidencijske infrastrukture, što zahtijeva razvoj alternativnih metodoloških pristupa.

## 4.1. Analiza LinkedIn podataka: strani radnici iz Nepala

Empirijska analiza temelji se na ukupno 81 analiziranom LinkedIn profilu. Za kvalitativnu analizu migracijskih obrazaca u tablicama su prikazana po tri do pet ilustrativnih profila za svaku od četiri nacionalne skupine. U istraživanje su uključeni radnici iz Nepala, Indije, Bangladeša i Filipina jer te skupine posljednjih godina čine najveći dio useljeničke populacije iz Azije u Hrvatskoj, prema ranije spomenutim podacima Ministarstva unutarnjih poslova. Odabir skupina stoga se temelji na njihovoj zastupljenosti u suvremenim migracijskim tokovima prema Hrvatskoj.[9]

Analiza LinkedIna s ključnom riječi „Nepal“ za lokaciju „Hrvatska“ i „Zagreb“ identificirala je 23 javno vidljiva korisnika nepalskog podrijetla koji se trenutačno nalaze i rade u Hrvatskoj, pretežito u Zagrebu. Najveći broj stranih radnika nalazi se u Zagrebu (DZS, 2026). Profili obuhvaćaju zanimanja od čišćenja i skladištenja do poduzetništva i vlasništva etničkih trgovina, a migracijske rute uključuju dolaske iz Katra, Ujedinjenih Arapskih Emirata i Saudijske Arabije te izravnu migraciju iz Nepala.

Prvi profil pokazuje vertikalnu mobilnost: nakon dolaska potkraj 2023. i rada kao čistač, sredinom 2025. strani radnik prelazi na stabilniji i bolje plaćen posao u Hrvatskoj pošti. Drugi profil pokazuje sekundarnu migraciju iz Dohe u Hrvatsku te unutarnju mobilnost iz Osijeka u Zagreb, bez promjene radne

[9] Radi zaštite privatnosti svi su profili anonimizirani, a podaci koji bi mogli omogućiti identifikaciju pojedinaca uklonjeni su ili prikazani u agregiranom obliku.

niše. Treći profil pokazuje poduzetničku mobilnost: nakon rada u agenciji za zapošljavanje u Nepalu otvara trgovinu za nepalsku zajednicu i nastavlja raditi kao posrednik između radnika i hrvatskih poslodavaca. Četvrti profil potvrđuje učestalost prethodnog rada u zemljama Zaljeva i indicije organizirane migracije u Hrvatsku. Peti profil pokazuje mogućnost daljnje mobilnosti prema drugoj državi članici EU: nakon osam mjeseci rada u Hrvatskoj korisnik prelazi u Njemačku i nastavlja rad u istom sektoru, što upućuje na Hrvatsku kao tranzitnu fazu višefaznog migracijskog ciklusa.

Promatranih pet putanja pokazuje nekoliko obrazaca: migracijsku rutu Nepal – zemlje Zaljeva – Hrvatska, koncentraciju u logistici, čišćenju, trgovini i poduzetništvu, različite ishode profesionalne mobilnosti te razvoj etničke infrastrukture u Zagrebu. Dio profila upućuje i na mogućnost daljnje mobilnosti prema drugim državama članicama EU.

**Tablica 3. LinkedIn profili radnika iz Nepala (N = 5)**

| | Godina dolaska u HR | Migracijska ruta | Obrazovanje | Zanimanje u HR | Sektor | Grad/ Poslodavac | Trajanje rada u HR | Socijalna mobilnost | Napomena |
|---|---|---|---|---|---|---|---|---|---|
| **1** | 2023. | Nepal → Hrvatska | SSS | Čistač, zatim zaposlenik Hrvatske pošte | usluge / Pošta | Zagreb (komunalna tvrtka, HP) | 11/2023 – 05/2025; 06/2025 – traje | Da: prelazak u stabilno, stalno zaposlenje | Pozitivan primjer integracije |
| **2** | 2021. | Nepal → Katar → HR | SSS | Skladištar | Logistika / trgovina | Osijek (Distributer pića); Zagreb (F …-term) | 10/2021. – 06/2023; 06/2023. – traje | Ne: ostaje u istoj radnoj niši | Primjer sekundarne migracije unutar HR |
| **3** | 2023. | Nepal → Hrvatska | VSS (prvostupnik) | Poduzetnik; vlasnik trgovine; agencija za zapošljavanje | Poduzetništvo | Zagreb | 04/2023. – traje | Da, poduzetnik | |
| **4** | 2025. | UAE (Dubai) → HR | VSS (prvostupnik) | Šef kuhinje | Kuharstvo /turizam | Hrvatska | 2025. –traje | Da | 3 god. Iskustva u UAE |
| **5** | 2023. – 2024. | Nepal → HR → Njemačka | SSS | Vozač autobusa | Transport | -- | 2023. – 2024. (8 mj.) | Nije moguće odrediti | Prelazak u Njemačku |

## 4.2. Strani radnici iz Indije u Hrvatskoj

Analiza LinkedIn profila identificirala je ukupno 26 javno vidljivih korisnika indijskog podrijetla u Hrvatskoj. Prvi profil pokazuje profesionalni pad (deskilling): korisnik je u Indiji radio kao prokurist, a nakon dolaska u Hrvatsku u veljači 2023. zapošljava se kao skladištar, gdje i dalje radi. Drugi profil pokazuje višefaznu radnu tranziciju: nakon dolaska u listopadu 2022. radi u građevini, zatim deset mjeseci kao vozač Ubera, a od veljače 2024. kao skladištar u Klinča Selima, što upućuje na postupnu stabilizaciju zaposlenja.

Treći profil pokazuje usklađenost obrazovanja i zaposlenja. Korisnik, prvostupnik turizma, od 2023. radi u hotelu na Rabu, bez promjene sektora. Četvrti profil pokazuje poduzetničku mobilnost: nakon rada u agenciji za zapošljavanje u Indiji, u Zagrebu od 2020. vodi vlastitu agenciju koja povezuje strane radnike s hrvatskim poslodavcima. Posjeduje visoku stručnu spremu i u Hrvatskoj je dulje od pet godina, čime je stekao pravo trajnog boravka. Peti profil ponovno potvrđuje obrazac organizirane migracije iz zemalja Zaljeva prema Hrvatskoj.

Promatrani profili pokazuju različite ishode: od „deskillinga“ i višefazne radne tranzicije do sektorske stabilnosti i poduzetničke mobilnosti. Istodobno potvrđuju prisutnost prethodnog radnog iskustva u zemljama Zaljeva i posredničke uloge migracijskih agencija.

**Tablica 4. LinkedIn profili radnika iz Indije u Hrvatskoj (N = 5)**

| | Godina dolaska u HR | Migracijska ruta | Obrazovanje | Zanimanje u HR | Sektor | Lokacija / Poslodavac | Socijalna mobilnost | Napomena |
|---|---|---|---|---|---|---|---|---|
| **1** | 2023. | Indija → HR | SSS | Skladištar | Logistika / trgovina | Zagreb, Veliki skladištar | Ne: pad kvalifikacija (deskilling) | U Indiji radio kao prokurist |
| **2** | 2022. | Indija → HR | SSS | Građevinski radnik → Uber vozač → Skladištar | Građevina / transport / logistika | Samobor; Klinča Sela (veliki trgovački lanac) | Djelomično – prelazak u stabilniji sektor | Primjer višefazne radne tranzicije |
| **3** | 2023. | Indija → HR | VŠS (Prvostupnik turizma) | Hotelski radnik | Turizam | Rab, Hotel | Ne: ostaje u istom sektoru | |
| **4** | 2020. | Indija → HR | VŠS (Prvostupnik) | Poduzetnik/Agencija za uvoz radnika | Usluge | Zagreb | Da: poduzetnik | |

| | Godina dolaska u HR | Migracijska ruta | Obrazovanje | Zanimanje u HR | Sektor | Lokacija / Poslodavac | Socijalna mobilnost | Napomena |
|---|---|---|---|---|---|---|---|---|
| **5** | 2024. | UAE (Dubai) → Saudijska Arabija → HR | nije navedeno | Radnik u tvornici | Industrija | (Naziv uklonjen) Zagreb | Teško ustanoviti | Ima 2 god. i 10 mj. Iskustvo u UAE; 3 god. iskustvo u Saud. Arabiji |

## 4.3. Radnici iz Bangladeša u Hrvatskoj

Analiza dostupnih LinkedIn profila radnika iz Bangladeša (N = 18) pokazuje nekoliko jasnih obrazaca migracijskih putanja i sektorskog pozicioniranja. Prvi profil pokazuje deskilling: unatoč završenom studiju prvostupnika, korisnik više od dvije i pol godine radi u pekarnici u Zagrebu. Drugi profil, također prvostupnik, od početka 2025. radi kao pomoćni električar u Samoboru, što upućuje na ulazak u djelomično kvalificirani tehnički sektor.

Treći profil pokazuje drugačiji obrazac. Nakon rada u ugostiteljstvu u Dubaiju, korisnik 2023. dolazi u Hrvatsku i zapošljava se kao šef restorana u Zagrebu, čime zadržava kvalifikacijsku povezanost s prethodnim radom. Ovaj slučaj predstavlja najizraženiji primjer profesionalne usklađenosti unutar analizirane skupine. Profili 3., 4. i 5. dodatno upućuju na organiziranu migraciju iz zemalja Zaljeva prema Hrvatskoj.

Promatrani profili pokazuju koncentraciju u pekarnicama i trgovini, građevinskim i tehničkim poslovima te ugostiteljstvu, pri čemu dio radnika unatoč visokom obrazovanju ulazi u poslove ispod razine kvalifikacija. Platformski rad i dostava prisutni su u manjoj mjeri nego kod radnika iz Nepala i Indije. Radnici iz Bangladeša češće se pojavljuju u stabilnijim sektorima poput trgovine, pekarstva i ugostiteljstva.

**Tablica 5. LinkedIn profili radnika iz Bangladeša u Hrvatskoj (N = 5)**

| | Godina dolaska u HR | Migracijska ruta | Obrazo-vanje | Zanimanje u HR | Sektor | Lokacija / Poslodavac | Socijalna mobilnost | Napomena |
|---|---|---|---|---|---|---|---|---|
| **1** | 2023. | Bangladeš → HR | VŠS (prvostupnik) | Radnik u pekarnici | Prehrambena industrija / maloprodaja | Zagreb (pekarnica) | Ne: značajan „deskilling“ | Stabilno zaposlenje > 2,5 godine |
| **2** | 2025. | Bangladeš → HR | VŠS (prvostupnik) | Pomoćni električar | Građevina / instalacije | Samobor | Djelomično: ulazak u kvalificiraniji sektor | Početak radnog iskustva u HR 2025. |
| **3** | 2023. | Bangladeš → UAE (Dubai) → HR | VŠS (prvostupnik) | Voditelj restorana | Ugostiteljstvo / turizam | Zagreb (restoran) | Da: visoka profesionalna mobilnost | 3 god. iskustva u UAE |
| **4** | 2023. | Bangladeš → Saudijska Arabija → HR | VŠS (prvostupnik ekonomije) | Voditelj restorana | Ugostiteljstvo / turizam | Lanac hotela Zadar | Da: visoka profesionalna mobilnost | 4 god. i 7 mj. Iskustva u Saud. Ar. |
| **5** | 2022. | Katar (Doha) → HR | VŠS (prvostupnik hotelijerstva) | Voditelj restorana | Ugostiteljstvo / turizam | Turistički „resort“, Umag | Da: visoka profesionalna mobilnost | 17 god. i 2 mj. Iskustva u Kataru |

## 4.4. Radnici iz Filipina u Hrvatskoj

Literatura Filipince opisuje kao izrazito mobilnu i organizirano regrutiranu radnu snagu, često s prethodnim iskustvom rada u zemljama Zaljeva i sekundarnom migracijom prema Europi (Graham i Dutton, 2019). Analiza LinkedIn profila identificirala je 14 javno vidljivih korisnika iz Filipina, pri čemu većina ima prethodno iskustvo rada u Ujedinjenim Arapskim Emiratima, Bahreinu ili Katru.

Prvi profil pokazuje vertikalnu mobilnost: nakon rada u skladištu od 2019., korisnik 2022. prelazi na nadzornu poziciju. Posjeduje prvostupničku diplomu tehničkih znanosti, a radna putanja upućuje na uspješniju profesionalnu integraciju. Ovaj slučaj povezan je i s prevladavajućem javnom diskursu u Hrvatskoj o pozitivnijem tretmanu filipinskih radnika u odnosu na druge azijske skupine. Drugi profil pokazuje „deskilling“: nakon tri godine rada u Saudijskoj Arabiji, 2024. dolazi u Hrvatsku i zapošljava se u jednom trgovačkom lancu, iako ima prvostupničku diplomu šumarstva. Treći profil prelazi iz tehničko-industrijskog rada u Kataru u proizvodni sektor u Hrvatskoj.

Četvrti profil pokazuje kvalifikacijsku usklađenost: nakon četiri godine rada u Bahreinu kao terapeut, od 2023. radi u području wellnessa i kozmetike u Hrvatskoj. Peti profil, prvostupnik političkih znanosti, nakon više od osam godina rada na Bliskom istoku, uključujući sedam godina u UAE-u te iskustvo u Bahreinu i Katru, dolazi u Hrvatsku i radi u logistici. Njegov slučaj pokazuje deskilling i ograničenu mogućnost priznavanja kvalifikacija.

Promatrani profili pokazuju koncentraciju filipinskih radnika u logistici, trgovini i uslužnim djelatnostima, uz češće prethodno međunarodno iskustvo i pojedinačne slučajeve napredovanja u nadzorne uloge. U odnosu na analizirane skupine iz Nepala i Bangladeša, profili upućuju na veći potencijal profesionalne mobilnosti, ali taj zaključak ostaje istraživački indikativan zbog ograničenog korpusa.

**Tablica 6. LinkedIn profili radnika s Filipina u Hrvatskoj (N = 5)**

| ID | Godina dolaska u HR | Prethodna zemlja | Migracijska ruta | Obrazovanje | Zaposlenje u HR | Sektor | Lokacija / Poslodavac | Socijalna mobilnost | Napomena |
|---|---|---|---|---|---|---|---|---|---|
| **1** | 2019. | Filipini | Filipini → HR | VŠS (prvostupnik tehničke znanosti) | Skladištar → Nadzornica | Logistika | Zagreb | Da: napredovanje u nadzornika | Primjer uspješne profesionalne integracije |
| **2** | 2024. | Saudijska Arabija | Filipini → Saud. Arabija → HR | VŠS (prvostupnik šumarstva) | Radnik u Sparu | Maloprodaja / logistika | HR (veliki trgovački lanac) | Ne: „deskilling“ | 3 god. iskustva u Saudijskoj Arabiji |
| **3** | 2021. | Katar (Doha) | Filipini → Katar → HR | V?S (prvostupnik tehničkih znanosti) | Radnik u tvornici boja | Proizvodnja | HR | Ne: ostaje u niskokvalificiranim poslovima | |
| **4** | 2023. | Bahrein | Bahrein → HR | SSS | Masažerka | Kozmetički salon | Zagreb | Ostaje u istoj struci | 4 god. iskustva u Bahreinu |
| **5** | 2023. | Katar (Doha) | UAE → Katar → HR | VŠS (prvostupnik politologije) | Logistika | Pekarnica | HR | Ne: deskilling | 7 god. iskustva u UAE, 14 mjeseci u Bahreinu |

# 5. RASPRAVA

Digitalni tragovi upućuju na širu sektorsku raspodjelu, uključujući logistiku, građevinarstvo, maloprodaju, turizam, proizvodnju i wellness. U svim analiziranim skupinama pojavljuje se prethodno radno iskustvo u državama Zaljeva, što podupire koncept višefazne migracije (Wickramasekara, 2016). Hrvatska stoga za dio radnika predstavlja sljedeću fazu već postojećih transnacionalnih migracijskih lanaca, a ne nužno prvo odredište.

Prethodno međunarodno radno iskustvo povezano je i s kasnijom profesionalnom mobilnošću. Dio radnika nakon dolaska u Hrvatsku prelazi iz platformskog rada u stabilnije sektore, dok drugi nastavljaju zanimanja za koja su se kvalificirali u zemljama Zaljeva, osobito u turizmu, ugostiteljstvu i wellnessu. Analiza pokazuje da platformski rad (Wolt, Bolt, Uber i Glovo) predstavlja važan, ali ne i dominantan oblik zapošljavanja stranih radnika. Ovaj se nalaz temelji na analizi 33 profila unutar ukupnog digitalnog korpusa od 81 profila te se stoga odnosi na promatrani digitalni korpus, a ne na ukupnu populaciju stranih radnika u Hrvatskoj. Istodobno, značajan broj profila pokazuje „deskilling“, odnosno zapošljavanje ispod razine stečenih kvalifikacija.

Za dio analiziranih radnika Hrvatska može predstavljati i važnu fazu dugoročnije migracije. Značajan broj profila pokazuje tri do četiri godine boravka, nakon čega se približava mogućnost stjecanja stalnog boravka. Za razliku od većine država Zaljeva (Hossain, 2018), hrvatski pravni okvir omogućuje stalni boravak nakon pet godina zakonitoga neprekinutog boravka. Ipak, duljina boravka sama po sebi ne znači uspješnu integraciju. Primjeri profesionalnog napredovanja i deskillinga potvrđuju da dugotrajniji boravak ne mora nužno dovesti do socioekonomske integracije (Peach, 2002; Koopmans, 2017). Kod dijela filipinskih radnika zabilježeni su češći primjeri profesionalnog napredovanja, ali tu razliku zbog eksplorativnog karaktera istraživanja treba provjeriti na većem korpusu.

Metodološki doprinos istraživanja jest u mogućnosti rekonstrukcije migracijskih putanja, profesionalne mobilnosti i sektorske koncentracije koje nisu vidljive iz administrativnih evidencija. Time se potvrđuje vrijednost digitalne demografije kao komplementarnog pristupa istraživanju migracija (Kitchin, 2014; Cesare i sur., 2018; Coimbra Vieira i sur., 2022). Istodobno, LinkedIn nije reprezentativan za ukupnu populaciju stranih radnika jer su na platformi zastupljeniji obrazovaniji i digitalno aktivniji korisnici. Digitalne

tragove stoga treba kombinirati sa službenim izvorima, a ne koristiti kao njihovu zamjenu.

Nalazi također upućuju na važnu ulogu posredničkih agencija u povezivanju stranih radnika i hrvatskih poslodavaca te u oblikovanju višefaznih migracijskih tokova. Njihova uloga u dugoročnoj profesionalnoj mobilnosti i integraciji ostaje pitanje za buduća istraživanja. Za migracijsku politiku to znači potrebu za kvalitetnijim praćenjem migracijskih putanja, profesionalne mobilnosti i integracijskih ishoda, pri čemu digitalni izvori mogu nadopuniti administrativne evidencije.

## 6. ZAKLJUČAK

Istraživanje pokazuje da LinkedIn može biti vrijedan dopunski izvor službenim evidencijama u proučavanju radnih migracija u Hrvatskoj. Na temelju digitalnog korpusa od 81 javno dostupnog profila identificirani su obrasci višefazne migracije, sektorske koncentracije i profesionalne mobilnosti koji nisu u cijelosti vidljivi u administrativnim i statističkim evidencijama. Kod 26 profila vidljiv je prethodni boravak u državama Zaljeva, što potvrđuje da se dolazak u Hrvatsku kod dijela radnika odvija kao faza šireg migracijskog procesa. Analiza također pokazuje različite obrasce profesionalne mobilnosti, uključujući profesionalno snižavanje kvalifikacija i prijelaze između sektora, kao i prisutnost platformskog rada unutar promatranog korpusa.

Nalazi potvrđuju da digitalna demografija može proširiti analitički uvid u migracijske putanje i profesionalne obrasce stranih radnika, ali ne može zamijeniti službene izvore. LinkedIn je selektivan i profesionalno usmjeren izvor, a javno dostupni podaci dijelom su samoprijavljeni, zbog čega rezultati imaju eksplorativni karakter i ne mogu se generalizirati na ukupnu populaciju stranih radnika. Vrijednost pristupa stoga je prije svega u triangulaciji digitalnih tragova i administrativnih podataka. Za migracijsku politiku to upućuje na potrebu kvalitetnijeg povezivanja različitih izvora podataka radi praćenja migracijskih putanja, profesionalne mobilnosti i integracijskih ishoda.

# LITERATURA

Banić, F., Pripužić, D. i Rebić, P. (2024). Što nam različite statistike govore o broju stranih radnika u Hrvatskoj i kako se te brojke odražavaju na potencijalni BDP?, HNB. Dostupno na https://www.hnb.hr/-/sto-nam-razlicite-statistike-govore-o-broju-stranih-radnika-u-hrvatskoj-i-kako-se-te-brojke-odrazavaju-na-potencijalni-bdp

Balabanić, I. i sur. (2025). Istraživački izvještaj anketnog istraživanja o kvaliteti života i obrascima života stranih radnika iz Azije i Afrike u Hrvatskoj. Dostupno na https://dabar.srce.hr/islandora/object/imin%3A188

Butković, H., Samardžija, V. i Rukavina I. (2022). Strani radnici u Hrvatskoj: Izazovi i mogućnosti za gospodarski i društveni razvoj. Institut za razvoj i međunarodne odnose. Institut za razvoj i međunarodne odnose, IRMO. Dostupno na https://irmo.hr/wp-content/uploads/2022/03/Strani-radnici-u-Hrvatskoj.pdf

Castles, S. (2010). Understanding Global Migration: A Social Transformation Perspective. Journal of Ethnic and Migration Studies, 36(10), 1565–1586. https://doi.org/10.1080/1369183X.2010.489381

Cesare N, Lee H, McCormick T, Spiro E, Zagheni E. Promises and Pitfalls of Using Digital Traces for Demographic Research. Demography. 2018 Oct;55(5):1979-1999. doi: 10.1007/s13524-018-0715-2

DZS (2023). Dostupno na https://podaci.dzs.hr/2023/hr/58061.

DZS (2026). Migracija stanovništva Republike Hrvatske u 2025. Dostupno na https://podaci.dzs.hr/2026/hr/121583

Gardner, A. M. (2011). City of Strangers: Gulf Migration and the Indian Community in Bahrain. (1 ed.). Ithaca: Cornell University Press. https://dx.doi.org/10.1353/book.27485.

Graham, M. i Dutton, W. (2019). Society and the Internet: How Networks of Information and Communication are Changing Our Lives, 2nd edn (Oxford, 2019; online edn, Oxford Academic, 19 Sept. 2019), https://doi.org/10.1093/oso/9780198843498.001.0001

Grgas, G. (2024). Gdje je 30 tisuća stranih radnika koji nisu u evidenciji HZMO-a, a imaju važeće radne dozvole? *Forbes.* (13.2.2024). Dostupno na https://forbes.dnevnik.hr/aktualno/gdje-je-30-tisuca-stranih-radnika-koji-nisu-u-evidenciji-hzmo-a-a-imaju-vazece-radne-dozvole/?

Hossain, J. (2018). Migration, Market and Institution: A Bangladesh Paradox through Gender Lens. SJPG 42/1. Dostupno na https://share.google /rRJi5F7bFiJ7nW3qP

IMIN (2025). Građani Hrvatske o stranim radnicima. Dostupno na https://strani-radnici.com/gradjani-hrvatske-o-stranim-radnicima

Jurić, T. (2022). Forecasting Migration and Integration Trends Using Digital Demography – A Case Study of Emigration Flows from Croatia to Austria and Germany. *Comparative Southeast European Studies*, vol. 70, no. 1, 2022, https://doi.org/10.1515/soeu-2021-0090

Jurić, T. (2023). Immigration to Croatia: Big (Migration) Data Approach. *Rad Hrvatske akademije znanosti i umjetnosti. Razred za društvene znanosti*, (560=57), 145-174. https://doi.org/10.21857/9e31lhzw8m

Jurić, T. (2024). Integracija imigranata u Hrvatskoj: načela učinkovitog integracijskog modela. *Crkva u svijetu, 59* (3), 483-517. https://doi.org/ 10.34075/cs.59.3.2

Jurić, T. (2025). Suvremene migracije i opstanak nacije, Školska knjiga, Zagreb.

Kim, J., Sîrbu, A., Giannotti, F., Gabrielli, L. (2020). Digital Footprints of International Migration on Twitter. In: Berthold, M., Feelders, A., Krempl, G. (eds) *Advances in Intelligent Data Analysis XVIII. IDA 2020. Lecture Notes in Computer Science*(), vol 12080. Springer, Cham. https://doi.org/10.1007/978-3-030-44584-3_22.

Kitchin, R. (2014). *The Data Revolution*. Sage, https://doi.org/10.4135/ 9781473909472.

Koopmans, R. (2017). *Assimilation oder Multikulturalismus? Bedingungen gelungener Integration*, Litt.

Kraler, A., D'Orazio, M., Pignoni, M., i Schmidt, S.(2010). Statistics on Migration, Integration and Discrimination in Europe: *PROMINSTAT Final Report*. ICMPD, Beč. Dostupno na https://www.icmpd.org/file/ download/48265/file/Statistics%20on%20Migration,%20Integration%20and %20Discrimination%20in%20Europe.%20PROMINSTAT%20Final%20Re port%20EN.pdf

Economicgraph.linkedin.com. Dostupno na https://economicgraph.linkedin. com/research?selectedFilter=all

MROSP. Dostupno na https://mrosp.gov.hr/UserDocsImages/dokumenti/Uprava%20za%20tr%C5%BEi%C5%A1te%20rada/POPIS%20AGENCIJA%20ZA%20POSREDOVANJE%20PRI%20ZAPO%C5%A0LJAVANJU.pdf

MUP (2025). Dostupno na https://mup.gov.hr/gradjani-281562/moji-dokumenti-281563/stranci-333/statistika-169019/169019?

MUP (2026). Dostupno na https://mup.gov.hr/UserDocsImages/statistika/2026/1/Mjesecne%20statistike%20prosinac%202025.pdf?vel=470528

Peach, C. (2002). Social geography: new religions and ethnoburbs – contrasts with cultural geography, *Progress in Human Geography*, Vol. 26, 2. https://doi.org/10.1191/0309132502ph36.

Perrotta, D., Johnson, S. C., Theile, T., Grow, A., Valk, H. de, & Zagheni, E. (2022). Openness to Migrate Internationally for a Job: Evidence from LinkedIn Data in Europe. *Proceedings of the International AAAI Conference on Web and Social Media*, *16*(1), 759–769. https://doi.org/10.1609/icwsm.v16i1.19332

Rahman, M. M. (2012). Bangladeshi labour migration to the Gulf states: patterns of recruitment and processes. Canadian Journal of Development Studies/Revue canadienne d études du développement, 33(2):214-230, DOI: 10.1080/02255189.2012.689612

Spyratos, S. i sur. (2018). *Migration Data using Social Media*. Eur Perspect JRC Tech Rep Eur Comm (2018). https://doi.org/10.2760/964282.

Siddiqui, T. (2003). *Migration as a Livelihood Strategy of the Poor:The Bangladesh Case.*. DFID. Country Background Paper, WP-C1, Sussex, UK, DRC on Migration, Globalisation and Poverty. Dostupno na https://www.gov.uk/research-for-development-outputs/working-paper-c1-migration-as-a-livelihood-strategy-of-the-poor-the-bangladesh-case

Coimbra Vieira, C., Fatehkia, M., Garimella, K,, Weber, I., Zagheni, E. (2022). Using Facebook and LinkedIn Data to Study International Mobility in: Salah, Albert Ali, Emre Eren Korkmaz, and Tuba Bircan (eds), Data Science for Migration and Mobility (London, 2022; online edn, British Academy Scholarship Online,https://doi.org/10.5871/bacad/9780197267103.001.0001.

Wickramasekara, P. (2016). South Asian Gulf migration to the Gulf: a safety valve or a development strategy? Migration and Development, 5(1), 99–129. DOI: 10.1080/21632324.2015.1039770

Alexander, M., Polimis, M., Zagheni, E. (2020). Combining Social Media Data and Traditional Surveys to Nowcast Migration Stocks in the United States. *Population Research and Policy Review*, https://doi.org/10.1007/s11113-020-09599-3

# FOREIGN WORKERS FROM ASIAN COUNTRIES IN THE REPUBLIC OF CROATIA: A DIGITAL-DEMOGRAPHIC ANALYSIS OF MIGRATION AND INTEGRATION PATTERNS

***Abstract***

*The aim of this paper is to examine whether LinkedIn, as a source of digital traces, can complement official administrative sources in the analysis of labour migration and early indicators of integration among foreign workers in Croatia. The study focuses on workers from the Philippines, India, Nepal, and Bangladesh, with particular attention to stepwise migration and previous residence in the Gulf States.*

*The study applies a digital demography approach to a corpus of 81 publicly available LinkedIn profiles, triangulating digital traces with administrative data from the Ministry of the Interior, the Croatian Pension Insurance Institute, and the Croatian Employment Service. The contribution of the paper is twofold. First, it systematically documents discrepancies between the administrative records of the Ministry of the Interior, the Croatian Pension Insurance Institute, and the Croatian Employment Service and the statistical records of the Croatian Bureau of Statistics, showing that these discrepancies reflect a systematic methodological difference rather than an error in any individual source. Second, the analysis of the corpus of 81 profiles identifies patterns of stepwise migration through the Gulf States, sectoral concentration by nationality, and professional downgrading of qualifications (deskilling). Previous residence in the Gulf States is visible in 26 profiles.*

*A limitation of the study arises from the selective nature of LinkedIn, whose publicly available profiles represent a self-selected and professionally oriented segment of the foreign-worker population and are not representative of its overall structure. The originality of the paper lies in applying digital demography and LinkedIn to the study of labour migration in Croatia and in connecting digital professional traces with official administrative sources. The findings demonstrate that digital traces can serve as a valuable complementary source for identifying migration and professional patterns that are not fully visible in official statistics.*

***Keywords:*** *foreign workers, digital demography, LinkedIn, integration, migration.*

JEL klasifikacija: E22, G12, L86, O33, Q41
Prethodno priopćenje

# TEHNOLOŠKE REVOLUCIJE I UMJETNA INTELIGENCIJA: EKONOMIKA IZGRADNJE PODATKOVNIH CENTARA

Tomislav Baković*

## SAŽETAK

Svrha – Cilj je rada utvrditi ponavlja li aktualni investicijski ciklus umjetne inteligencije (UI) povijesni obrazac tehnoloških revolucija te, na primjeru podatkovnih centara, ispitati podupiru li troškovi, prihodi, cijena energije i očekivana profitabilnost izgradnje taj obrazac. Dizajn/metodologija/pristup – Rad se temelji na pregledu literature o tehnološkim revolucijama, tehnologijama opće namjene i financijskim ciklusima te na deskriptivnoj statistici sekundarnih podataka uz komparativnu analizu izgradnje podatkovnih centara u SAD-u, Kini i Europskoj uniji. Rezultati i implikacije – Empirijski profil UI ciklusa – kapitalna ulaganja četiriju najvećih hiperskalera od približno 725 mlrd. USD u 2026., statistički potvrđene epizode eksplozivnog rasta cijena dionica i skromni tekući učinci na produktivnost – dosljedan je obrascu instalacijskog razdoblja tehnoloških revolucija. Tri regije pokazuju tri režima iste revolucije: tržišno alociranu izgradnju s rekordnom popunjenošću (SAD, 0,3 % slobodnih kapaciteta), politički alociranu izgradnju s viškom (Kina, iskorištenost 20–30 %) te potražnju bez vlastite ponude (EU). Energija je ključna odrednica isplativosti:

* Prof. dr. sc. Tomislav Baković, Sveučilište u Zagrebu, Ekonomski fakultet (e-mail: tbakovic@efzg.hr).

europske veleprodajne cijene struje dvostruko su više od američkih, što po gigavatu stvara troškovni jaz od više stotina milijuna USD godišnje. Ograničenja – Rad se oslanja na sekundarne podatke i procjene čija se metodologija razlikuje, a brzina promjena ograničava vremensku valjanost zaključaka. Originalnost – Rad povezuje literaturu o tehnološkim revolucijama s komparativnom ekonomikom podatkovnih centara triju regija, uključujući strukturu korisnika, prihoda i energetskih troškova, te predlaže pokazatelje za praćenje ciklusa.

**Ključne riječi:** tehnološke revolucije, umjetna inteligencija, podatkovni centri, kapitalna ulaganja, cijena energije.

# 1. UVODNA RAZMATRANJA

Dvije brojke sažimaju neobičnost trenutka u kojem se svjetsko gospodarstvo nalazi. Prva: aplikacija ChatGPT dosegnula je početkom 2023. godine sto milijuna korisnika u dva mjeseca, brže od bilo koje potrošačke tehnologije u povijesti. Druga: četiri najveća pružatelja računalstva u oblaku – Microsoft, Alphabet, Amazon i Meta – najavila su za 2026. godinu kapitalna ulaganja od približno 725 mlrd. USD – rast od 77 % u odnosu na 410 mlrd. USD godinu prije. Između te dvije brojke stoji pitanje koje dijeli akademsku i investicijsku javnost: gradi li se infrastruktura nove tehnološke ere ili se ponavlja obrazac prekomjernog ulaganja poznat iz manije željeznica (1847.), ekspanzije elektrifikacije, radija i automobila koja je prethodila slomu burze (1929.) te dot-com balona internetskih dionica (2000.).

Ekonomska povijest nudi bogat materijal za usporedbu. Svaka od velikih tehnologija posljednja dva stoljeća – željeznica, elektrifikacija, automobil, internet – prošla je kroz razdoblje u kojem je kapital u infrastrukturu ulazio brže nego što su prihodi mogli opravdati, a vrednovanja rasla brže od difuzije tehnologije (Perez, 2002; Freeman i Louçã, 2001; Jovanovic i Rousseau, 2005). Aktualni ciklus umjetne inteligencije (dalje: UI) prvi je koji se može promatrati u stvarnom vremenu, na podacima o izgradnji konkretne fizičke imovine: podatkovnih centara. Upravo zato ovaj rad ekonomiku njihove izgradnje – troškove, korisnike, energiju, prihode i očekivanu profitabilnost – uzima kao empirijski test teze o ponavljanju povijesnog obrasca.

Postavljaju se tri istraživačka pitanja: (1) koje pravilnosti tehnoloških revolucija literatura dokumentira i po čemu se instalacijska razdoblja prepoznaju; (2) odgovara li empirijski profil UI ciklusa – brzina difuzije,

dinamika cijena imovine i učinci na produktivnost – tim pravilnostima te (3) što ekonomika izgradnje podatkovnih centara u trima ključnim regijama, SAD-u, Kini i Europskoj uniji, govori o održivosti tekućih ulaganja. Nakon pregleda literature i metodologije slijede empirijski profil UI kao najnovije disrupcije, komparativna analiza ekonomike podatkovnih centara, rasprava i zaključna razmatranja.

# 2. PREGLED LITERATURE

## 2.1. Tehnološke revolucije i dinamika kapitala

Ideja da tehnološki napredak dolazi u valovima, a ne kontinuirano, seže do Schumpetera (1942) i pojma kreativne destrukcije: inovacije istodobno stvaraju nove industrije i obezvrjeđuju postojeće strukture kapitala. Freeman i Louçã (2001) tu ideju razrađuju u povijesnoj analizi dugih valova, a najutjecajniju sintezu nudi Perez (2002), koja u posljednjih 240 godina identificira pet tehnoloških revolucija – od industrijske revolucije do informacijskog doba – sa zajedničkom unutarnjom strukturom. Svaka se revolucija odvija kroz instalacijsko razdoblje, u kojem financijski kapital špekulativno gradi infrastrukturu nove paradigme, i implementacijsko razdoblje, u kojem produktivni kapital tu infrastrukturu puni stvarnom ekonomskom aktivnošću; između njih stoji točka preokreta, povijesno obilježena slomom ili krizom. Iz te perspektive balon nije anomalija, nego mehanizam kojim društvo financira infrastrukturu koju bi pojedinačno racionalni ulagači teško opravdali (Tablica 1.).

**Tablica 1. Instalacijska razdoblja tehnoloških revolucija i njihovi slomovi**

| Revolucija | Infrastruktura instalacijskog razdoblja | Vrhunac mahnitosti | Slom i posljedice |
|---|---|---|---|
| Doba pare i željeznica | željeznička mreža Velike Britanije | 1845. – 1847.; ulaganja ≈ 7 % BDP-a | kriza 1847.; mreža postaje temelj viktorijanske ekspanzije |
| Doba čelika i elektriciteta | elektrane, mreže, dinamo-strojevi | 1880-e – 1900-e | produktivni učinci vidljivi tek 1920-ih (David, 1990) |
| Doba nafte i automobila | ceste, rafinerije, masovna proizvodnja | 1920-e; radio i automobilske dionice | slom 1929.; difuzija paradigme nakon 1945. |
| Informacijsko doba | optička vlakna, serveri, web | 1998. – 2000.; CAPE 44 (prosinac 1999.) | NASDAQ −78 % (2000. – 2002.); infrastruktura nosi širokopojasnu ekonomiju |

Izvor: sistematizacija autora prema Perez (2002), Freeman i Louçã (2001), David (1990) i Shiller (2015).

Ofek i Richardson (2003) pokazuju da su vrednovanja internetskih dionica 2000. godine implicirala tržišne udjele koji su u zbroju višestruko premašivali veličinu tržišta, a Jovanovic i Rousseau (2005) da uvođenje tehnologija opće namjene sustavno prate valovi ulaska na burzu i povišena volatilnost. Garber (1990) pritom upozorava da se dio naizgled iracionalnih cijena može objasniti fundamentima, zbog čega etiketiranje tržišnih epizoda zahtijeva empirijsku podlogu.

## 2.2. Tehnologije opće namjene i paradoks produktivnosti

Drugi tok literature objašnjava zašto se koristi revolucionarnih tehnologija materijaliziraju sporo. Bresnahan i Trajtenberg (1995) tehnologije opće namjene definiraju kroz sveprisutnost, kontinuirano poboljšanje i komplementarne inovacije. Upravo komplementarnost objašnjava vremenski odmak: David (1990) dokumentira da je elektrifikacija američke industrije trebala približno četiri desetljeća da se pretoči u mjerljiv rast produktivnosti jer je zahtijevala redizajn tvornica, procesa i vještina. Brynjolfsson, Rock i Syverson (2021) taj mehanizam formaliziraju kao „J-krivulju

produktivnosti“: u ranoj fazi difuzije statistika bilježi troškove ulaganja u neopipljivu imovinu, ali ne i njihove buduće prinose. Za UI konkretno, Acemoglu (2025) procjenjuje kumulativni učinak na ukupnu faktorsku produktivnost SAD-a od svega oko 0,7 % u desetljeću, dok Aghion, Jones i Jones (2019) pokazuju da bi učinci mogli biti znatno veći ako UI ubrza i samu proizvodnju ideja. Crafts (2021) povijesnom usporedbom zaključuje da je UI po strukturi tipična tehnologija opće namjene – s učincima koji su realni, ali sporiji od tržišnih očekivanja.

## 2.3. Financijska dinamika tehnoloških ciklusa

Treći tok literature opisuje kako se tehnološki optimizam pretvara u financijsku nestabilnost. Kindleberger i Aliber (2015) identificiraju ponavljajuću sekvencu pomak–uzlet–euforija–kriza, a Minsky (1986) nudi taksonomiju po kojoj se financijske strukture kreću od zaštićenih (obveze se servisiraju iz tekućeg novčanog toka) preko špekulativnih do Ponzijevih (obveze se servisiraju novim zaduživanjem), pri čemu stabilnost sustava opada kako udio potonjih raste. Pástor i Veronesi (2009) pokazuju da su „balonolike“ putanje cijena racionalno objašnjive prirodom novih tehnologija: dok je rizik idiosinkratičan, vrednovanja rastu, a kada tehnologija postane sistemski važna, vrednovanja se komprimiraju. Empirijski, Greenwood, Shleifer i You (2019) utvrđuju da udvostručenje cijena industrije u dvije godine značajno povećava vjerojatnost naknadnog sloma, Phillips, Shi i Yu (2015) razvijaju GSADF test kojim se epizode eksplozivnog rasta cijena statistički identificiraju, a Basele, Phillips i Shi (2025) tim testom dokumentiraju eksplozivne epizode u indeksu NASDAQ i svih sedam najvećih tehnoloških dionica u razdoblju 2017. – 2025.

# 3. METODOLOGIJA ISTRAŽIVANJA

U radu se primjenjuje deskriptivna statistika temeljena na sekundarnim podacima. Izvori obuhvaćaju izvješća specijaliziranih istraživačkih kuća (CBRE, Rystad Energy, Epoch AI), konzultantskih društava (Bain & Company), međunarodnih organizacija i agencija (IEA, EIA), dokumente Europske komisije te revidirana financijska izvješća i javne objave promatranih društava. Podaci se odnose na razdoblje 2024. – 2026., uz povijesne usporedbe od 2017. godine.

Analiza se provodi u tri koraka. Prvo se empirijski profil UI ciklusa (brzina difuzije, kapitalna ulaganja, dinamika cijena imovine, učinci na produktivnost) uspoređuje s pravilnostima instalacijskih razdoblja iz pregleda literature. Zatim se sistematizira troškovna i prihodovna struktura podatkovnog centra kapaciteta 1 GW te izračunava implicirani godišnji prihod potreban za isplativost ulaganja. Naposljetku se komparativnom analizom uspoređuju tri ključne regije – SAD, Kina i EU – prema opsegu ulaganja, strukturi korisnika, iskorištenosti kapaciteta, cijeni i izvorima energije te izvorima financiranja. Budući da se metodologije pojedinih izvora razlikuju, umjesto jedne brojke navodi se raspon procjena iz više neovisnih izvora, a svaki se ključni podatak veže uz izvor.

## 4. UMJETNA INTELIGENCIJA KAO NAJNOVIJA TEHNOLOŠKA DISRUPCIJA

Generativni modeli UI zadovoljavaju definicijska svojstva tehnologije opće namjene: primjenjivi su u većini sektora, poboljšavaju se iz generacije u generaciju i induciraju komplementarne inovacije, od novih poluvodiča do novih poslovnih modela (Bresnahan i Trajtenberg, 1995; Crafts, 2021). Istodobno imaju i obilježja disruptivne inovacije u smislu Christensena (1997), jer redefiniraju strukturu troškova postojećih industrija. Brzina početne difuzije bez presedana je – sto milijuna korisnika ChatGPT-a u dva mjeseca – a materijalni trag jednako je mjerljiv: prema IEA (2025), potrošnja električne energije podatkovnih centara udvostručit će se do 2030. na 945 TWh, gotovo 3 % svjetske potrošnje, nakon što je desetljećima stagnirala zahvaljujući dobicima učinkovitosti (Masanet i sur., 2020).

Financijska dinamika ciklusa slijedi obrazac opisan u pregledu literature. Kapitalna ulaganja četiriju najvećih hiperskalera rastu s približno 230 mlrd. USD u 2024. na 410 mlrd. USD u 2025. i planiranih 725 mlrd. USD u 2026., a kumulativne procjene za razdoblje 2025. – 2030. dosežu 5.300 milijardi USD. Na tržištima kapitala Shillerov ciklički prilagođeni omjer cijene i zarade (CAPE) premašio je 40, drugu najvišu razinu od 1871. (Shiller, 2015), sedam najvećih tehnoloških društava čini više od trećine kapitalizacije indeksa S&P 500, a GSADF testovi potvrđuju eksplozivne epizode u šest od sedam tih dionica od prosinca 2022. (Basele i sur., 2025). Tržište pritom već diferencira: Nvidia je u siječnju 2025. u jednom danu izgubila oko 600 mlrd.

USD kapitalizacije nakon objave troškovno učinkovitijeg kineskog modela DeepSeek.

Treći element profila – raskorak između ulaganja i mjerljivih učinaka – također je prisutan: procjene učinka UI na produktivnost mjere se u desetinkama postotka (Acemoglu, 2025), a J-krivulja sugerira da će se stvarni učinci vidjeti tek s difuzijom komplementarnih ulaganja (Brynjolfsson i sur., 2021; David, 1990). Kombinacija triju nalaza – iznimno brza difuzija očekivanja, kapitalna ulaganja koja rastu brže od prihoda i spori učinci na produktivnost – empirijski je potpis instalacijskog razdoblja. Najstroža provjera te teze, međutim, nije na tržištima kapitala, nego u realnoj ekonomiji: u računici izgradnje podatkovnih centara, kojoj se rad sada okreće.

# 5. EKONOMIKA IZGRADNJE PODATKOVNIH CENTARA

## 5.1. Struktura troškova, energija i zahtijevana profitabilnost

Podatkovni centri fizička su infrastruktura UI ciklusa, kao što su to bile pruge za doba pare i optička vlakna za internet. Jedinica analize jest objekt kapaciteta 1 GW. Procjene ukupnih kapitalnih troškova kreću se od 35 mlrd. USD (Bernstein) preko 38 mlrd. USD (Epoch AI, 2025) do 47–60 mlrd. USD za najnoviju generaciju arhitekture (procjene Foxconna i Nvidije). Oko 60 % kapitalnih troškova otpada na IT opremu, ponajprije grafičke procesore, čiji je ekonomski vijek trajanja svega 3–5 godina, dok građevine i energetska infrastruktura traju 15–30 godina. U operativnim troškovima dominira energija: objekt od 1 GW troši oko 8,3 TWh godišnje, što pri američkim cijenama znači godišnji račun od oko 1,3 mlrd. USD (Tablica 2.). Energija je stoga, uz cijenu opreme, druga strukturna odrednica isplativosti: svaka razlika od 10 USD/MWh u cijeni struje mijenja godišnji trošak objekta od 1 GW za oko 80 mil. USD.

**Tablica 2. Troškovna struktura UI podatkovnog centra kapaciteta 1 GW**

| Stavka | Iznos / raspon | Napomena |
|---|---|---|
| Ukupni kapitalni trošak (capex) | 35–60 mlrd. USD | ovisno o generaciji opreme |
| Udio IT opreme (GPU, serveri, mreža) | ≈ 60 % capexa | amortizacija 3–5 godina |
| Građevine i energetska infrastruktura | ≈ 25–30 % capexa | amortizacija 15–30 godina |
| Godišnja potrošnja / trošak energije | ≈ 8,3 TWh; ≈ 1,3 mlrd. USD | pri američkim cijenama; u EU ≈ dvostruko |
| Implicirani potrebni godišnji prihod | ≈ 10–13 mlrd. USD po GW | uz 10 % IRR, izračun autora |

Izvor: izračun i sistematizacija autora prema Epoch AI (2025), CBRE (2026), IEA (2026) i javno dostupnim procjenama proizvođača opreme.

Računica je zahtjevna. Uz kapitalni trošak od oko 40 mlrd. USD po GW, ponderirani vijek imovine kraći od sedam godina i zahtijevanu stopu povrata od 10 %, objekt od 1 GW mora generirati 10–13 mlrd. USD prihoda godišnje. Rizik na prihodovnoj strani već se materijalizira: cijena najma procesora H100 pala je s oko 7 USD po GPU-satu u 2023. na ispod 4 USD u 2025., pri čemu je AWS u lipnju 2025. snizio cijene za oko 44 % u jednom mjesecu nakon dolaska nove generacije opreme. Takva deflacija cijene računalne usluge erodira povrat na kapital uložen po višim nabavnim cijenama – dinamika koju literatura dokumentira na primjeru telekomunikacijskog prometa nakon 2000. godine (Ofek i Richardson, 2003). Na agregatnoj razini Bain & Company (2025) procjenjuje da bi ulaganja od 500 mlrd. USD godišnje do 2030. zahtijevala oko 2.000 milijardi USD godišnjih prihoda od UI, uz očekivani manjak od približno 800 mlrd. USD čak i pod velikodušnim pretpostavkama. Vodeća UI poduzeća, Anthropic i OpenAI, početkom 2026. bilježe anualizirane prihode od približno 30, odnosno 25 mlrd. USD – pri čemu je Anthropic, s pretežno poslovnim korisnicima, u travnju 2026. po prihodima prestigao OpenAI (Epoch AI, 2026).

## 5.2. Sjedinjene Američke Države

SAD je epicentar ciklusa i, na prvi pogled, opovrgava tezu o prekomjernoj izgradnji. Stopa slobodnih kolokacijskih kapaciteta u Sjevernoj Virginiji[1], najvećem svjetskom tržištu, pala je početkom 2026. na 0,3 %, cijene zakupa dosežu 190–235 USD po kW mjesečno uz rast od 13,8 % za velike zakupe, a kapacitet u izgradnji porastao je 80 % na 2.078 MW – pri čemu je većina kapaciteta za 2026. unaprijed zakupljena do u 2027. godinu (CBRE, 2026). Potražnja je, dakle, stvarna, testirana i plaćena unaprijed.

Energetska strana američke prednosti dvojaka je. S jedne strane, veleprodajne cijene električne energije približno su upola niže od europskih (IEA, 2026), a dominantni izvor je prirodni plin, uz rastući udio obnovljivih izvora. S druge strane, upravo je priključna snaga postala usko grlo: redovi čekanja za priključenje na mrežu mjere se godinama, pa hiperskaleri sklapaju dugoročne ugovore izravno s proizvođačima – Microsoft je s Constellationom ugovorio ponovno pokretanje nuklearne elektrane Three Mile Island (835 MW, na 20 godina), a Amazon zakup 960 MW nuklearnog kapaciteta elektrane Susquehanna (EIA, 2025). Rastuća potražnja podatkovnih centara već se prelijeva u više cijene za kućanstva u regijama poput PJM-a, što stvara i politički rizik za daljnju izgradnju.

Slika se mijenja kada se pogleda tko je potražnja. Najveći zakupci su sami hiperskaleri i laboratoriji UI modela (OpenAI, Anthropic), dok krajnju potražnju čine pretplate potrošača, naplata primjene modela poduzećima po korištenju te UI funkcionalnosti ugrađene u oglašavanje, pretraživanje i softver. Ranjivost lanca jest u tome što se njegov pretežiti dio odvija među povezanim stranama: Nvidia je najavila ulaganja do 100 mlrd. USD u OpenAI, koji se istodobno obvezao na kupnju Nvidijinih sustava i na višegodišnji zakup računalnog kapaciteta od Oraclea vrijedan oko 300 mlrd. USD (Reuters, 2025). Krajnji prihodi, reda veličine nekoliko desetaka milijardi USD godišnje, pokrivaju pritom oko desetinu godišnjeg capexa. U Minskyjevoj (1986) taksonomiji, dio tih struktura ima obilježja špekulativnih, a dijelom i Ponzijevih jedinica: servisiranje obveza ovisi o daljnjem priljevu kapitala, ne o tekućem novčanom toku. Valja, međutim, biti precizan: sami hiperskaleri većinu ulaganja financiraju iz operativnih novčanih tokova

[1] Sjeverna Virginija (tzv. „Data Center Alley“, ponajprije okrug Loudoun) najveća je svjetska koncentracija podatkovnih centara. Regija se razvila 1990-ih oko ranih internetskih čvorišta i kroz nju i danas prolazi znatan dio svjetskoga internetskog prometa, a blizina Washingtona osigurava i stabilnu potražnju državnog sektora.

temeljnih djelatnosti, pa sistemski rizik nije u njihovoj solventnosti, nego u povratu na uloženi kapital i u slabijim karikama lanca.

## 5.3. Kina

Kina nudi prirodni eksperiment s drugim mehanizmom alokacije: izgradnju predvode država i lokalne samouprave. Državna nabava računalnih kapaciteta dosegnula je 24,7 mlrd. juana (≈ 3,4 mlrd. USD) u 2024., uz dodatnih 12,4 mlrd. juana u 2025. (Australian Strategic Policy Institute [ASPI], 2026). Ishod je dokumentirana prekomjerna izgradnja: službene procjene iskorištenosti kreću se oko 20–30 %, prema pojedinim izvješćima do 80 % novih kapaciteta stoji neiskorišteno, a broj otkazanih projekata premašio je 100 u 18 mjeseci, prema 11 u cijeloj 2023. godini (ASPI, 2026; TechRadar, 2026). Ministarstvo industrije i informacijskih tehnologija razmatra stoga nacionalnu platformu za preprodaju viška kapaciteta, dok Rystad Energy (2026) projicira rast ukupnog kapaciteta na više od 60 GW do 2030. godine.

Energija je temelj kineske strategije – i dio objašnjenja viška. Oko 70 % električne energije kineskih podatkovnih centara dolazi iz ugljena, a program usmjeravanja obrade podataka s istoka na zapad smješta nove objekte uz jeftinu hidroenergiju Guizhoua i vjetar i sunce Unutarnje Mongolije (Oxford Institute for Energy Studies [OIES], 2026). Cijene su administrirane i niske, a centri koji koriste domaće poluvodiče od studenoga 2025. ostvaruju subvencije do 50 % cijene struje. Jeftina energija, međutim, ne može nadoknaditi pogrešnu lokaciju: komercijalna potražnja koncentrirana je kod velikih platformi (Alibaba, Tencent, ByteDance) u obalnim aglomeracijama, dok zapadni objekti s čipovima slabijih performansi i visokom mrežnom latencijom ostaju bez korisnika. Višak i nestašica tako koegzistiraju unutar iste zemlje. Uz iskorištenost od 20 do 30 %, očekivana profitabilnost većine objekata je negativna, a gubitke snose javni proračuni. U kineskom se slučaju tako ono što Perez (2002) naziva točkom preokreta – trenutak u kojem se vrijednosti stvorene u instalacijskom razdoblju moraju uskladiti s realnom potražnjom – odvija izravno u realnom sektoru, kroz prazne kapacitete i otpise javnog kapitala, bez posredovanja tržišta vrijednosnih papira.

Kineski odgovor na oskudicu najnaprednijih čipova ujedno je i radikalno drukčiji tehnološki pristup: otvoreni modeli optimizirani za učinkovitost. DeepSeek je model V3 istrenirao uz objavljeni računalni trošak od svega oko 5,6 mil. USD – prema stotinama milijuna za usporedive zapadne modele – a

njegov otvoreni nasljednik R1 izazvao je spomenuti jednodnevni pad Nvidije; slijede ga otvoreni modeli Alibabe (Qwen) i drugih. Ako se granica sposobnosti može dosegnuti uz red veličine manje resursa, upitna je središnja pretpostavka američkog ciklusa – da revolucija zahtijeva bilijunske kapacitete. Protuargument je Jevonsov paradoks: pojeftinjenje računalne usluge povijesno je povećavalo ukupnu potražnju. Koji će učinak prevladati, empirijsko je pitanje o kojem izravno ovisi isplativost izgrađenih kapaciteta.

## 5.4. Europska unija

EU je treći slučaj: potražnja bez vlastite ponude. Inicijativom InvestAI Europska komisija cilja mobilizirati oko 200 mlrd. EUR ulaganja do 2030., uključujući 20 mlrd. EUR za četiri do pet „UI gigatvornica" s više od 100.000 naprednih procesora po objektu, uz doprinos Unije do 17 % kapitalnih troškova i obvezno sufinanciranje država članica (Europska komisija, 2025). Za mjerilo: cjelokupni višegodišnji javni paket EU-a približno je jednak jednomjesečnom capexu američkih hiperskalera u 2026. Na komercijalnom tržištu europska središta (Frankfurt, London, Amsterdam, Pariz, Dublin) bilježe potražnju veću od ponude i rastuće cijene zakupa, no izgradnju usporavaju mrežna priključenja i dozvole (CBRE, 2026).

Najveći europski hendikep je energija. Prosječna veleprodajna cijena električne energije u EU iznosila je 2025. oko 95 USD/MWh – približno dvostruko više nego u SAD-u i gotovo 50 % više nego u Kini – a cijene za energetski intenzivnu industriju više su od dvostrukih američkih (IEA, 2026). Za objekt od 1 GW ta razlika znači 400–600 mil. USD viših godišnjih troškova, čime se briše velik dio moguće marže. Struktura izvora je povoljnija emisijski (obnovljivi izvori i nuklearna energija, osobito u Francuskoj i nordijskim zemljama, koje se zbog jeftine hidroenergije i nuklearne energije ističu kao najizglednije lokacije), ali mrežna ograničenja djeluju restriktivno: u Irskoj, gdje podatkovni centri troše više od petine nacionalne električne energije, priključenja oko Dublina bila su zamrznuta od 2021. do prosinca 2025., a nova pravila zahtijevaju vlastitu proizvodnju i pretežno obnovljive izvore (Bloomberg, 2025). Posljedica je asimetrija s dalekosežnim implikacijama: europska poduzeća i javni sektor računalne usluge pretežno kupuju od američkih pružatelja u njihovim europskim regijama, pa prihodi od europske potrošnje većim dijelom pripadaju američkim društvima. Rizik prekomjerne izgradnje u EU je zanemariv – ali po cijenu izostanka iz infrastrukture paradigme koja se upravo instalira.

## 5.5. Komparativna sinteza

Tablica 3. sažima ključne razlike triju regija prema opsegu ulaganja, nositeljima financiranja, strukturi korisnika, iskorištenosti, energiji i očekivanoj profitabilnosti.

**Tablica 3. Komparativni pokazatelji izgradnje podatkovnih centara: SAD, Kina i EU (2024. – 2026.)**

| Pokazatelj | SAD | Kina | EU |
|---|---|---|---|
| Opseg ulaganja | 725 mlrd. USD capex četiriju hiperskalera (2026.); 5.300 mlrd. USD kumulativno 2025. – 2030. | državna nabava 24,7 mlrd. juana (2024.); cilj > 60 GW do 2030. | cilj mobilizacije 200 mlrd. EUR do 2030.; 20 mlrd. EUR za gigatvornice |
| Nositelj financiranja | privatni kapital, rastući udio duga i SPV struktura | država i lokalne samouprave | javni kapital EU (do 17 % capexa) + države članice |
| Glavni korisnici kapaciteta | hiperskaleri i UI laboratoriji (predzakup); na kraju lanca potrošači i poduzeća | platforme grade vlastite objekte; subvencionirani kapaciteti bez identificiranih korisnika | poduzeća i javni sektor, pretežno kod američkih pružatelja oblaka |
| Iskorištenost / popunjenost | slobodni kapaciteti 0,3 % (Sjeverna Virginija); zakup unaprijed do 2027. | iskorištenost ≈ 20–30 %; do 80 % novih kapaciteta neiskorišteno | potražnja > ponude u FLAP-D središtima; spora izgradnja |
| Energija: cijena i izvori | ≈ ½ cijene EU; plin + nuklearni PPA-ovi (835 MW TMI, 960 MW Susquehanna); uska grla priključenja | niske administrirane cijene, subvencije do 50 %; ≈ 70 % ugljen, hidro i vjetar na zapadu | veleprodajno ≈ 95 USD/MWh (≈ 2× SAD); OIE + nuklearna; mrežna ograničenja (Dublin 2021. – 2025.) |
| Očekivana profitabilnost | kolokacija visoka; hiperskaleri ovisni o budućim UI prihodima (manjak ≈ 800 mlrd. USD do 2030.) | pretežno negativna; gubici socijalizirani u javnim proračunima | neizvjesna; strukturno niža zbog cijene energije i mjerila |

Izvor: sistematizacija autora prema CBRE (2026), Bain & Company (2025), IEA (2026), EIA (2025), ASPI (2026), Rystad Energy (2026) i Europskoj komisiji (2025).

# 6. RASPRAVA

Nalazi otkrivaju paradoks koji zaslužuje objašnjenje: regija koja ulaže najviše pati od nestašice kapaciteta, dok regija s politički usmjerenom izgradnjom raspolaže viškom od 70 do 80 % novih kapaciteta. Paradoks nestaje kada se uvaži da „kapacitet“ nije homogeno dobro – tražena su četiri rijetka resursa istodobno: priključna snaga na mreži u blizini korisnika, pouzdana i cjenovno konkurentna energija, najnovija generacija procesora i kreditno sposoban zakupac. Tri regije tako čine tri prirodna eksperimenta s mehanizmom alokacije kapitala. U SAD-u se potražnja testira prije izgradnje, kroz predzakup; u Kini se testirala tek nakon izgradnje, s poznatim ishodom; u EU se potražnja testira, ali se zbog ograničenja ponude namiruje uvozom usluge. Isti tehnološki šok, tri različita ishoda – razlika nije u tehnologiji, nego u instituciji koja alocira kapital.

Energija pritom nije sporedna stavka, nego strukturna odrednica konkurentnosti regija. Pri godišnjoj potrošnji od oko 8,3 TWh po gigavatu, razlika u cijeni struje od približno 45 USD/MWh između EU i SAD-a znači 350–400 mil. USD viših godišnjih operativnih troškova po objektu – prije nego što je ijedan token naplaćen. Tri regije stoga vode tri različite energetske politike izgradnje: SAD privatizira rješenje uskoga grla dugoročnim nuklearnim ugovorima i plinom, uz rastući politički rizik prelijevanja troškova na kućanstva; Kina energiju tretira kao industrijsku subvenciju, čime rješava trošak, ali ne i lokacijski nesklad između jeftine energije na zapadu i korisnika na istoku; EU ima najskuplju energiju i najsporija priključenja, pa se izgradnja seli prema jeftinoj hidroenergiji i nuklearnoj energiji Skandinavije i Francuske. Iz perspektive isplativosti, cijena energije određuje donju granicu cijene računalne usluge: u svijetu u kojem cijene najma procesora deflacioniraju, regija s dvostruko skupljom strujom prva pada ispod praga profitabilnosti.

Znači li sve to da je riječ o ponavljanju povijesnog obrasca prekomjernog ulaganja? Dokazi u prilog toj tezi su znatni: kapitalne obveze premašuju krajnje prihode industrije za red veličine, dio financijskih struktura ima minskyjevska obilježja ovisnosti o novom kapitalu, cijene računalne usluge deflacioniraju, a testovi eksplozivnosti potvrđuju odvajanje cijena dionica od fundamenata (Basele i sur., 2025; Greenwood i sur., 2019). Znanstvena korektnost, međutim, zahtijeva i protuargumente: hiperskaleri većinu ulaganja financiraju iz operativnih novčanih tokova, po čemu se ciklus razlikuje od telekomunikacijske epizode 1990-ih; J-krivulja i povijest

elektrifikacije upozoravaju da skromni tekući učinci ne dokazuju izostanak budućih (David, 1990; Brynjolfsson i sur., 2021); a dio vrednovanja može odražavati racionalnu opcijsku vrijednost rijetkih resursa – priključne snage, energije i lokacija (Garber, 1990). Konačan sud stoga ovisi o razlučujućim pokazateljima koje je moguće pratiti: dinamici krajnjih prihoda (zatvara li se jaz prema 2.000 milijardi USD iz procjene Bain & Company), iskorištenosti novih kapaciteta izvan kruga povezanih strana, kretanju cijena računalne usluge u odnosu na amortizacijske pretpostavke te učinku otvorenih, resursno štedljivih modela na potražnju za računalnim kapacitetom.

Bez obzira na to koji scenarij prevlada, literatura nudi dvije pouke. Prva: slom vrednovanja povijesno nije značio kraj tehnologije, nego smjenu vlasnika – infrastruktura izgrađena uz gubitke ulagača u pravilu je, po sniženim cijenama, postala temelj sljedeće faze rasta, kao pruge nakon 1847. i optička vlakna nakon 2002. (Perez, 2002); najranjiviji su stoga poslovni modeli čiji prihodi ovise o nastavku ubrzanja kapitalnih ulaganja, a ne o difuziji tehnologije prema krajnjim korisnicima. Druga pouka tiče se ekonomske politike: kineski slučaj pokazuje da javno usmjeravanje izgradnje bez tržišnog testa potražnje proizvodi kapacitet, ali ne i vrijednost, a europski da izostanak ulaganja ima vlastitu cijenu – stratešku ovisnost o tuđoj infrastrukturi. Između tih dvaju neuspjeha, uklanjanje uskih grla ponude (mrežnih priključenja, dozvola i cijene energije) jeftinija je i tržišno konzistentnija politika od javnog sufinanciranja izgradnje.

## 7. ZAKLJUČNA RAZMATRANJA

Rad je aktualni UI ciklus usporedio s pravilnostima tehnoloških revolucija dokumentiranima u literaturi te ga empirijski testirao na ekonomici izgradnje podatkovnih centara u SAD-u, Kini i EU. Četiri su glavna nalaza. Prvo, empirijski profil ciklusa – najbrža difuzija potrošačke tehnologije u povijesti, kapitalna ulaganja od 725 mlrd. USD u 2026. koja rastu brže od prihoda, statistički potvrđene eksplozivne epizode cijena dionica i učinci na produktivnost mjereni u desetinkama postotka – dosljedan je obrascu instalacijskih razdoblja željeznica, elektrifikacije i interneta. Drugo, računica podatkovnih centara pokazuje da isplativost izgradnje ovisi o rastu krajnjih prihoda industrije za red veličine u nekoliko godina, dok deflacija cijena računalne usluge i kratak vijek opreme taj zahtjev pooštravaju. Treće, energija je strukturna odrednica konkurentnosti: dvostruko više europske cijene struje stvaraju jaz od više stotina milijuna USD godišnje po gigavatu, kineska

subvencionirana energija ne nadoknađuje lokacijski nesklad, a američka jeftina energija dolazi s uskim grlima priključenja. Četvrto, tri regije predstavljaju tri režima iste revolucije – tržišno testiranu izgradnju s neizvjesnim povratom (SAD), politički alociran višak s negativnom profitabilnošću (Kina) i potražnju bez vlastite ponude (EU) – što sugerira da o ishodu tehnološke revolucije ne odlučuje tehnologija, nego mehanizmi alokacije kapitala i energije.

Ograničenja rada proizlaze iz oslanjanja na sekundarne podatke i procjene industrijskih izvora čija se metodologija razlikuje, iz brzine promjena koja skraćuje vremensku valjanost brojki te iz izostanka vlastite ekonometrijske analize. Buduća istraživanja trebala bi obuhvatiti mikropodatke o povratima pojedinačnih podatkovnih centara, strukturu krajnjih prihoda po segmentima korisnika te praćenje predloženih razlučujućih pokazatelja. Doprinos rada leži u povezivanju literature o tehnološkim revolucijama s komparativnom ekonomikom podatkovnih centara triju regija na provjerenim podacima, uključujući energetsku dimenziju, čime se rasprava o UI ciklusu pomiče od pitanja hoće li korekcija nastupiti prema pitanju tko snosi njezine troškove i tko će naslijediti njezinu infrastrukturu.

# LITERATURA

Acemoglu, D. (2025). The simple macroeconomics of AI. Economic Policy, 40(121), 13–58. https://doi.org/10.1093/epolic/eiae042

Aghion, P., Jones, B. F. i Jones, C. I. (2019). Artificial intelligence and economic growth. U: Agrawal, A., Gans, J. i Goldfarb, A. (Ur.), The Economics of Artificial Intelligence: An Agenda (str. 237–282). Chicago: University of Chicago Press.

Australian Strategic Policy Institute (2026). Abundant electricity isn't enough: China's overbuilt AI computing power is underused. Canberra: ASPI. Dostupno na https://www.aspistrategist.org.au

Bain & Company (2025). Global Technology Report 2025. Boston: Bain & Company. Dostupno na https://www.bain.com/insights/topics/technology-report/

Basele, R. B., Phillips, P. C. B. i Shi, S. (2025). Speculative bubbles in the recent AI boom: Nasdaq and the Magnificent Seven. Journal of Time Series Analysis, 46(5), 814–828. https://doi.org/10.1111/jtsa.12835

Bloomberg (2025). Ireland ends moratorium on new power links to data centers. Dostupno na https://www.bloomberg.com

Bresnahan, T. F. i Trajtenberg, M. (1995). General purpose technologies: 'Engines of growth'? Journal of Econometrics, 65(1), 83–108. https://doi.org/10.1016/0304-4076(94)01598-T

Brynjolfsson, E., Rock, D. i Syverson, C. (2021). The productivity J-curve: How intangibles complement general purpose technologies. American Economic Journal: Macroeconomics, 13(1), 333–372. https://doi.org/10.1257/mac.20180386

CBRE (2026). Global Data Center Trends 2026. Dallas: CBRE Research. Dostupno na https://www.cbre.com/insights

Christensen, C. M. (1997). The Innovator's Dilemma: When New Technologies Cause Great Firms to Fail. Boston: Harvard Business School Press.

Crafts, N. (2021). Artificial intelligence as a general-purpose technology: An historical perspective. Oxford Review of Economic Policy, 37(3), 521–536. https://doi.org/10.1093/oxrep/grab012

David, P. A. (1990). The dynamo and the computer: An historical perspective on the modern productivity paradox. American Economic Review, 80(2), 355–361. Dostupno na https://www.jstor.org/stable/2006600

EIA (2025). Data center owners turn to nuclear as potential electricity source. Washington: U.S. Energy Information Administration. Dostupno na https://www.eia.gov/todayinenergy/detail.php?id=63304

Epoch AI (2025). Total cost of ownership of a one-gigawatt AI data center. Dostupno na https://epoch.ai/data-insights

Epoch AI (2026). Anthropic could surpass OpenAI in annualized revenue by mid-2026. Dostupno na https://epoch.ai/data-insights

Europska komisija (2025). InvestAI initiative and AI Gigafactories. Bruxelles: Europska komisija. Dostupno na https://digital-strategy.ec.europa.eu/en/policies/ai-factories

Freeman, C. i Louçã, F. (2001). As Time Goes By: From the Industrial Revolutions to the Information Revolution. Oxford: Oxford University Press.

Garber, P. M. (1990). Famous first bubbles. Journal of Economic Perspectives, 4(2), 35–54. https://doi.org/10.1257/jep.4.2.35

Greenwood, R., Shleifer, A. i You, Y. (2019). Bubbles for Fama. Journal of Financial Economics, 131(1), 20–43. https://doi.org/10.1016/j.jfineco.2018.09.002

IEA (2025). Energy and AI. Pariz: International Energy Agency. Dostupno na https://www.iea.org/reports/energy-and-ai

IEA (2026). Electricity 2026. Pariz: International Energy Agency. Dostupno na https://www.iea.org/reports/electricity-2026

Jovanovic, B. i Rousseau, P. L. (2005). General purpose technologies. U: Aghion, P. i Durlauf, S. N. (Ur.), Handbook of Economic Growth (sv. 1B, str. 1181–1224). Amsterdam: Elsevier. https://doi.org/10.1016/S1574-0684(05)01018-X

Kindleberger, C. P. i Aliber, R. Z. (2015). Manias, Panics and Crashes: A History of Financial Crises (7. izd.). Basingstoke: Palgrave Macmillan.

Masanet, E., Shehabi, A., Lei, N., Smith, S. i Koomey, J. (2020). Recalibrating global data center energy-use estimates. Science, 367(6481), 984–986. https://doi.org/10.1126/science.aba3758

Minsky, H. P. (1986). Stabilizing an Unstable Economy. New Haven: Yale University Press.

Ofek, E. i Richardson, M. (2003). DotCom mania: The rise and fall of internet stock prices. Journal of Finance, 58(3), 1113–1137. https://doi.org/10.1111/1540-6261.00560

Oxford Institute for Energy Studies (2026). The China data centre advantage. Oxford: OIES. Dostupno na https://www.oxfordenergy.org

Pástor, Ľ. i Veronesi, P. (2009). Technological revolutions and stock prices. American Economic Review, 99(4), 1451–1483. https://doi.org/10.1257/aer.99.4.1451

Perez, C. (2002). Technological Revolutions and Financial Capital: The Dynamics of Bubbles and Golden Ages. Cheltenham: Edward Elgar.

Phillips, P. C. B., Shi, S. i Yu, J. (2015). Testing for multiple bubbles: Historical episodes of exuberance and collapse in the S&P 500. International Economic Review, 56(4), 1043–1078. https://doi.org/10.1111/iere.12132

Reuters (2025). Nvidia to invest up to $100 billion in OpenAI, 22. rujna 2025. Dostupno na https://www.reuters.com

Rystad Energy (2026). China's data center capacity set to top 60 GW by 2030. Oslo: Rystad Energy.

Schumpeter, J. A. (1942). Capitalism, Socialism and Democracy. New York: Harper & Brothers.

Shiller, R. J. (2015). Irrational Exuberance (3. izd.). Princeton: Princeton University Press.

TechRadar (2026). China has spent billions of dollars building far too many data centers for AI and compute. Dostupno na https://www.techradar.com/pro

# TECHNOLOGICAL REVOLUTIONS AND ARTIFICIAL INTELLIGENCE: THE ECONOMICS OF DATA CENTRE CONSTRUCTION

***Abstract***

*Purpose – The paper examines whether the current artificial intelligence (AI) investment cycle repeats the historical pattern of technological revolutions and, using data centres as its case, tests whether the costs, revenues, energy prices and expected profitability of construction support that pattern. Design/methodology/approach – The study rests on a review of the literature on technological revolutions, general purpose technologies and financial cycles, and on descriptive statistics of secondary data (CBRE, IEA, Bain & Company, the European Commission, corporate financial reports), with a comparative analysis of data centre construction in the USA, China and the European Union. Findings and implications – The empirical profile of the AI cycle – capital expenditure of the four largest hyperscalers of approximately USD 725 billion in 2026, statistically confirmed episodes of explosive share price growth, and modest current productivity effects – is consistent with the installation-period pattern of technological revolutions. The three regions display three regimes of the same revolution: market-allocated construction at record occupancy (USA, 0.3% vacancy), politically allocated construction with surplus (China, 20–30% utilisation), and demand without domestic supply (EU). Energy is a key determinant of profitability: European wholesale electricity prices are roughly twice US levels, a cost gap of several hundred million USD per gigawatt annually. Limitations – The paper relies on secondary data and estimates whose methodologies differ, and the speed of change limits the temporal validity of the conclusions. Originality – The paper links the literature on technological revolutions with a three-region comparison of data centre economics, including the structure of users, revenues and energy costs, and proposes indicators for monitoring the cycle.*

***Keywords:*** *technological revolutions, artificial intelligence, data centres, capital expenditure, energy prices.*

JEL klasifikacija: O33, M15, D83
Prethodno priopćenje

# PROCESNA PRIMJENA UMJETNE INTELIGENCIJE U PODUZEĆIMA: USPOREDBA HRVATSKE I EUROPSKE UNIJE PREMA VELIČINI PODUZEĆA

Ivan Jajić*

## SAŽETAK

Glavna ideja rada jest ispitati razlikuje li se procesna primjena umjetne inteligencije prema veličini poduzeća te kako se Hrvatska pozicionira u odnosu na države članice Europske unije. Svrha rada je analizirati procesnu primjenu umjetne inteligencije u poduzećima Europske unije i Hrvatske, s naglaskom na automatizaciju radnih tokova i potporu odlučivanju. Istraživanje se temelji na Eurostat podacima za razdoblje 2023. – 2025. i obuhvaća 27 država članica EU-a (EU-27) prema trima veličinskim skupinama poduzeća. Primjenjuju se deskriptivna i komparativna analiza, analiza jaza, Friedmanov test i Wilcoxonovi testovi. Rezultati pokazuju da primjena umjetne inteligencije raste, ali je snažno povezana s veličinom poduzeća. Hrvatska zaostaje za neponderiranim prosjekom EU-27 u svim veličinskim skupinama, pri čemu je relativno najnepovoljniji položaj vidljiv kod malih poduzeća. Ograničenje rada proizlazi iz uporabe jednog pokazatelja koji ne mjeri izravno produktivnost ni poslovnu vrijednost.

* Dr. sc. Ivan Jajić, Sveučilište u Zagrebu, Ekonomski fakultet (e-mail: ijajic@net.efzg.hr).

Doprinos rada je u empirijskoj analizi procesne primjene umjetne inteligencije prema veličini poduzeća te u komparativnom pozicioniranju Hrvatske u odnosu na države članice Europske unije.

**Ključne riječi**: umjetna inteligencija, automatizacija radnih tokova, potpora odlučivanju, poduzeća, Hrvatska, EU-27.

# 1. UVOD

Umjetna inteligencija (engl. artificial intelligence – AI) ubraja se među najvažnije disruptivne tehnologije suvremenoga gospodarstva jer mijenja način na koji organizacije prikupljaju, obrađuju i koriste informacije. Organizacija za ekonomsku suradnju i razvoj (engl. Organisation for Economic Co-operation and Development – OECD) umjetnu inteligenciju promatra u širem okviru novih tehnologija čiji se učinci ne mogu razumjeti samo kroz tehničke mogućnosti, nego i kroz način njihova upravljanja i organizacijske primjene (OECD, 2024). Rana, Pillai, Sivathanu i Malik (2024) pokazuju da usvajanje generativne umjetne inteligencije nije samo tehničko pitanje, nego je povezano s organizacijskom izvedbom, etičkim razmatranjima i načinom na koji se AI uklapa u postojeće organizacijske aktivnosti. Iako se dio literature korištene u radu odnosi specifično na generativnu umjetnu inteligenciju, ti se izvori koriste za razmatranje organizacijskih aspekata usvajanja i primjene umjetne inteligencije, dok se empirijska analiza ovog rada odnosi na AI tehnologije u širem smislu kako ih obuhvaća Eurostatov pokazatelj.

Sama uporaba umjetne inteligencije ne znači nužno i stvaranje poslovne vrijednosti. Kumar, Shankar, Hollebeek, Behl i Lim (2025) ističu da se primjena generativne umjetne inteligencije u poslovanju treba promatrati kroz stvarnu uporabu, organizacijsku prilagodbu i sposobnost stvaranja koristi u konkretnim radnim situacijama. Singla, Sukharevsky, Yee, Chui i Hall (2025) dodatno naglašavaju da organizacije ostvaruju veću vrijednost od AI-ja kada ne ostaju samo na razini uporabe alata, nego prilagođavaju radne tokove, odgovornosti i načine odlučivanja.

U ovom se radu izraz procesna primjena umjetne inteligencije koristi kao operativna oznaka za Eurostatov pokazatelj koji obuhvaća poduzeća koja koriste AI tehnologije za automatizaciju različitih radnih tokova ili pomoć pri odlučivanju (Eurostat, 2026). Fokus na tom pokazatelju odabran je zato što se odnosi na uporabu umjetne inteligencije u konkretnim organizacijskim

aktivnostima povezanima s radnim tokovima i odlučivanjem. Arroyabe, Arranz, Fernandez de Arroyabe i Fernandez de Arroyabe (2024) pokazuju da usvajanje umjetne inteligencije u europskim malim i srednjim poduzećima ovisi o digitalnim sposobnostima, inovacijskim kapacitetima i vanjskom okruženju, što dodatno upućuje na važnost organizacijskog konteksta u kojem se AI primjenjuje. U empirijskom dijelu ovoga rada ne provodi se izravna usporedba opće i procesne uporabe umjetne inteligencije. Stoga se analizirani pokazatelj ne tumači kao izravna mjera organizacijske sposobnosti, zrelosti ili dubine integracije umjetne inteligencije, nego kao pokazatelj njezine uporabe u navedenim organizacijskim funkcijama.

Takav je pristup posebno relevantan za informacijske znanosti jer se ne bavi samo pitanjem posjeduje li poduzeće određenu tehnologiju, nego načinom na koji se informacijsko-komunikacijska tehnologija koristi u organizacijskom kontekstu. Polisetty, Chakraborty, G, Kar i Pahari (2024) pokazuju da odluka o primjeni umjetne inteligencije ovisi o kombinaciji tehnoloških, organizacijskih i upravljačkih čimbenika. Iz te perspektive AI se može promatrati kao dio šireg informacijskog sustava koji utječe na obradu podataka, automatizaciju zadataka, potporu odlučivanju i organizacijsku učinkovitost.

Primjena umjetne inteligencije istodobno otvara pitanja odgovornosti, nadzora i organizacijskog upravljanja. Američki Nacionalni institut za standarde i tehnologiju (engl. National Institute of Standards and Technology – NIST) u okviru za upravljanje rizicima umjetne inteligencije naglašava važnost mapiranja, mjerenja, upravljanja i nadziranja AI rizika (NIST, 2023). Međunarodna organizacija za normizaciju i Međunarodno elektrotehničko povjerenstvo (engl. International Organization for Standardization i International Electrotechnical Commission – ISO/IEC) normom ISO/IEC 42001:2023 definiraju zahtjeve za sustav upravljanja umjetnom inteligencijom u organizacijama (ISO/IEC, 2023). Novelli, Taddeo i Floridi (2024) odgovornost u umjetnoj inteligenciji povezuju s jasnom raspodjelom uloga, objašnjivošću, nadzorom i mogućnošću praćenja učinaka AI sustava.

Ovaj se rad nadovezuje na prethodno postavljen stručni okvir prema kojem ulaganje u umjetnu inteligenciju treba promatrati kao stratešku, organizacijsku i upravljačku odluku, a ne samo kao tehnološku investiciju. Jajić (2026) ističe da poslovna vrijednost AI-ja ne proizlazi iz same implementacije tehnologije, nego iz jasne poslovne svrhe, organizacijske spremnosti, definiranih odgovornosti i kontinuiranog nadzora. Novi doprinos ovoga rada nalazi se u tome što se navedeni konceptualni pristup empirijski

nadograđuje analizom Eurostat podataka o uporabi umjetne inteligencije za automatizaciju radnih tokova i potporu odlučivanju u poduzećima Europske unije i Hrvatske.

Cilj rada je analizirati postoje li razlike u primjeni umjetne inteligencije za automatizaciju radnih tokova i potporu odlučivanju prema veličini poduzeća te utvrditi položaj Hrvatske u odnosu na neponderirani prosjek EU-27, odnosno skupine od 27 država članica Europske unije. Istraživačko pitanje glasi: postoje li razlike u primjeni umjetne inteligencije za automatizaciju radnih tokova i potporu odlučivanju prema veličini poduzeća u državama Europske unije te kakva je pozicija Hrvatske u odnosu na neponderirani prosjek EU-27? Polazeći od toga, postavljaju se četiri hipoteze: H1 – velika poduzeća češće koriste umjetnu inteligenciju za automatizaciju radnih tokova i potporu odlučivanju od malih i srednjih poduzeća; H2 – primjena umjetne inteligencije u automatizaciji radnih tokova i potpori odlučivanju raste u razdoblju 2023. – 2025.; H3 – Hrvatska zaostaje za neponderiranim prosjekom EU-27; H4 – relativno zaostajanje Hrvatske najizraženije je kod malih poduzeća.

Znanstveni doprinos rada očituje se u empirijskoj analizi procesne primjene umjetne inteligencije prema veličini poduzeća te u komparativnom pozicioniranju Hrvatske u odnosu na države članice Europske unije. Aplikativni doprinos proizlazi iz mogućnosti korištenja rezultata za prepoznavanje veličinskih skupina poduzeća u kojima je procesna primjena AI-ja manje zastupljena te za usmjeravanje mjera potpore primjeni umjetne inteligencije.

## 2. TEORIJSKI OKVIR

Razna literatura upućuje na to da se umjetna inteligencija u poduzećima ne može promatrati samo kao tehnička inovacija, nego kao tehnologija koja mijenja način korištenja podataka, informacija i automatiziranih sustava. Rana i suradnici (2024) već su istaknuli da usvajanje generativne umjetne inteligencije uključuje organizacijske i etičke dimenzije, dok Kumar i suradnici (2025) naglašavaju da se poslovna vrijednost AI-ja pojavljuje tek kroz stvarnu uporabu i organizacijsku prilagodbu. Takvi nalazi upućuju na to da je za razumijevanje učinaka AI-ja važno promatrati način njegove integracije u konkretne organizacijske aktivnosti.

U teorijskom okviru rada korisno je konceptualno razgraničiti opću uporabu umjetne inteligencije od uporabe AI-ja u konkretnim organizacijskim

procesima. Arroyabe i suradnici (2024) pokazuju da usvajanje AI-ja u europskim malim i srednjim poduzećima ovisi o digitalnim sposobnostima, inovacijskim kapacitetima i vanjskom okruženju. Takvi nalazi upućuju na to da je, uz samu uporabu AI tehnologija, relevantno promatrati i organizacijska područja u kojima se one koriste. U ovom je radu fokus na uporabi AI-ja za automatizaciju radnih tokova i potporu odlučivanju, pri čemu se taj pokazatelj ne tumači kao izravna mjera dubine ili zrelosti organizacijske integracije AI-ja.

Umjetna inteligencija ima izravnu vezu s informacijskim sustavima jer utječe na prikupljanje, obradu i korištenje informacija u organizaciji. Polisetty i suradnici (2024) pokazuju da odluka o primjeni AI-ja u poduzećima ovisi o tehnološkim, organizacijskim i upravljačkim čimbenicima. U tom je smislu AI relevantan za informacijske znanosti jer se ne odnosi samo na algoritme, nego i na organizacijsku sposobnost korištenja podataka, automatizaciju zadataka i potporu odlučivanju.

U širem institucionalnom i upravljačkom kontekstu, Tipurić (2025) upozorava da obrasci negativne selekcije, slabljenje profesionalnih standarda i pad institucionalnog povjerenja mogu ograničiti sposobnost organizacija da donose kvalitetne strateške odluke, što je posebno važno kod složenih ulaganja u disruptivne tehnologije.

Važnost upravljačke i nadzorne dimenzije digitalne transformacije naglašavaju Tušek, Ježovita i Halar (2018), koji ističu da nove digitalne tehnologije mijenjaju poslovne modele, donošenje odluka, upravljanje rizicima i sustave internih kontrola. Njihov pristup upućuje na važnost podatkovne osnove, nadzora, odgovornosti i organizacijskih pretpostavki pri uključivanju novih digitalnih tehnologija u postojeće upravljačke procese.

Pokazatelj korišten u ovom radu obuhvaća uporabu AI tehnologija za automatizaciju različitih radnih tokova ili pomoć pri odlučivanju. On ne omogućuje izravnu procjenu organizacijske zrelosti, sposobnosti integracije ni ekonomskih učinaka primjene umjetne inteligencije. Stoga se rezultati tumače kao pokazatelj zastupljenosti takvog oblika uporabe među poduzećima, a ne kao mjera stupnja organizacijske zrelosti ili poslovne vrijednosti AI-ja.

Organizacijska i podatkovna spremnost posebno su važne za uspješnu primjenu umjetne inteligencije. Oldemeyer, Jede i Teuteberg (2025) u sustavnom pregledu literature o AI-ju u malim i srednjim poduzećima ističu da su izazovi primjene povezani s dostupnošću podataka, kompetencijama,

resursima i razumijevanjem mogućnosti tehnologije. Rajaram i Tinguely (2024) dodatno naglašavaju da mala i srednja poduzeća mogu imati koristi od generativne umjetne inteligencije, ali se istodobno suočavaju s ograničenjima u znanju, resursima, upravljanju rizicima i sposobnosti integracije AI-ja u svakodnevne aktivnosti.

Veličina poduzeća važna je analitička dimenzija u proučavanju procesne primjene umjetne inteligencije. Schwaeke, Peters, Kanbach, Kraus i Jones (2025) pokazuju da je usvajanje AI-ja u malim i srednjim poduzećima sve važnija istraživačka tema, ali i da ta poduzeća nemaju jednake kapacitete kao velika poduzeća. D'Amico, Audretsch, Belitski i Colombelli (2026) dodatno pokazuju da usvajanje AI-ja u malim i srednjim poduzećima ovisi o znanju, ulaganjima u digitalne tehnologije, unutarnjim sposobnostima i vanjskoj suradnji. Iz toga proizlazi pretpostavka da velika poduzeća, zbog razvijenijih informacijskih sustava, većih količina podataka, formaliziranijih radnih tokova i više specijaliziranih kadrova, mogu imati povoljnije pretpostavke za primjenu AI-ja za automatizaciju i potporu odlučivanju.

Pitanje umjetne inteligencije nije samo pitanje usvajanja tehnologije, nego i pitanje odgovornosti, nadzora i organizacijskog upravljanja. Novelli i suradnici (2024) naglašavaju da odgovornost u umjetnoj inteligenciji treba razumjeti kroz jasnu raspodjelu uloga, objašnjivost, nadzor i mogućnost praćenja učinaka AI sustava. To je posebno važno u kontekstu automatizacije radnih tokova i potpore odlučivanju jer se tada AI uključuje u aktivnosti koje mogu imati izravne organizacijske, ekonomske i upravljačke posljedice.

Dosadašnja literatura upućuje na zaključak da umjetna inteligencija može biti poticaj disruptivnih promjena u poduzećima, ali samo ako se poveže s podacima, kompetencijama, organizacijskim kapacitetima i jasnom svrhom uporabe. Schwaeke i suradnici (2025) naglašavaju da se mala i srednja poduzeća suočavaju s posebnim ograničenjima u primjeni AI-ja, dok D'Amico i suradnici (2026) pokazuju da znanje i digitalne sposobnosti imaju važnu ulogu u usvajanju AI-ja. Na toj se osnovi u ovom radu procesna primjena umjetne inteligencije promatra kroz uporabu AI-ja za automatizaciju radnih tokova i potporu odlučivanju, pri čemu se posebna pozornost posvećuje razlikama prema veličini poduzeća i položaju Hrvatske u odnosu na države članice Europske unije.

# 3. PODACI I METODOLOGIJA

Empirijski dio rada temelji se na podacima Eurostata o uporabi umjetne inteligencije u poduzećima prema veličini poduzeća. U radu se koristi pokazatelj koji se odnosi na poduzeća koja koriste AI tehnologije za automatizaciju različitih radnih tokova ili pomoć pri odlučivanju. Pokazatelj je odabran jer izravno obuhvaća uporabu AI tehnologija u organizacijskim aktivnostima povezanima s automatizacijom radnih tokova i odlučivanjem. U radu se za tako definiranu uporabu koristi operativni naziv procesna primjena umjetne inteligencije.

Analiza obuhvaća razdoblje od 2023. do 2025. godine i države članice Europske unije za koje su dostupni potpuni podaci za sve tri promatrane godine i sve tri veličinske skupine poduzeća. U istraživanje je uključeno 27 država članica EU-a. Za svaku državu promatraju se tri godine i tri veličinske skupine poduzeća, pa ukupan broj opažanja iznosi 243, odnosno 27 država × 3 godine × 3 veličinske skupine.

Glavni pokazatelj izražen je kao postotak poduzeća koja koriste umjetnu inteligenciju za automatizaciju radnih tokova ili pomoć pri odlučivanju. Jedinica analize jest država članica Europske unije prema godini i veličinskoj skupini poduzeća. Analiza razlikuje mala poduzeća s 10–49 zaposlenih, srednja poduzeća s 50–249 zaposlenih i velika poduzeća s 250 i više zaposlenih.

Budući da je cilj rada usporediti države članice Europske unije i pozicionirati Hrvatsku u odnosu na ostale države članice, u radu se koristi neponderirani aritmetički prosjek EU-27. Takav pristup svakoj državi članici daje jednaku težinu. Ne koristi se službeni ponderirani agregat Eurostata jer bi takav pokazatelj bio snažno pod utjecajem većih gospodarstava i broja poduzeća u pojedinim državama. Neponderirani prosjek stoga je prikladniji za komparativnu analizu država članica i položaja Hrvatske unutar EU-a. Budući da je Hrvatska jedna od 27 država uključenih u izračun neponderiranog prosjeka, njezine vrijednosti u maloj mjeri utječu i na referentni prosjek s kojim se uspoređuju, što treba uzeti u obzir pri interpretaciji odstupanja Hrvatske od prosjeka EU-27.

U radu se koriste deskriptivna statistika, komparativna analiza, analiza trenda, analiza odstupanja Hrvatske od neponderiranog prosjeka EU-27, rang analiza i analiza veličinskog jaza između malih i velikih poduzeća. Podaci su agregirani na razini država članica, pa rezultati ne opisuju ponašanje

pojedinačnih poduzeća, nego nacionalne obrasce primjene AI-ja prema veličinskim skupinama. Takav pristup omogućuje usporedbu Hrvatske s drugim državama članicama, ali zahtijeva oprez u tumačenju rezultata jer se zaključci odnose na agregirane pokazatelje.

Za statističku provjeru razlika koriste se neparametrijski testovi jer se uspoređuju povezane skupine podataka na razini država članica. Conover (1999) navodi da su neparametrijski testovi prikladni kada nije opravdano pretpostaviti normalnost distribucije i kada se analiziraju rangovi ili povezani uzorci. Hollander, Wolfe i Chicken (2013) Friedmanov test opisuju kao neparametrijsku alternativu za usporedbu više povezanih skupina, dok Corder i Foreman (2011) Wilcoxonov test predlažu za parne usporedbe povezanih mjerenja.

Za testiranje razlika prema veličini poduzeća koristi se Friedmanov test jer se za iste države članice uspoređuju tri povezane veličinske skupine: mala, srednja i velika poduzeća. Za parne usporedbe između veličinskih skupina koriste se Wilcoxonovi testovi uz korekciju p-vrijednosti zbog višestrukih usporedbi. Friedmanov test koristi se i za ispitivanje promjena kroz vrijeme, posebno za svaku veličinsku skupinu poduzeća. Kao mjera veličine učinka prikazuje se Kendallov W. Rezultati se interpretiraju na razini statističke značajnosti $p < 0,001$. Tablica 1. prikazuje opis podataka i metodološki okvir.

**Tablica 1. Opis podataka i metodološki okvir**

| Element | Opis |
|---|---|
| Izvor podataka | Eurostat |
| Pokazatelj | Poduzeća koja koriste AI za automatizaciju radnih tokova ili pomoć pri odlučivanju |
| Razdoblje | 2023. – 2025. |
| Obuhvat | Države članice EU-a s potpunim podacima za sve tri godine i sve tri veličinske skupine |
| Veličina poduzeća | 10-49, 50-249, 250+ zaposlenih |
| Jedinica mjere | Postotak poduzeća |
| Jedinica analize | Država-godina-veličinska skupina |
| Broj opažanja | 27 država × 3 godine × 3 veličinske skupine = 243 opažanja |
| Vrsta EU prosjeka | Neponderirani aritmetički prosjek država članica EU-27 |

Izvor: izrada autora prema podacima Eurostata (2026).

Promatrani pokazatelj ne mjeri izravno produktivnost, profitabilnost ni poslovnu vrijednost umjetne inteligencije. On mjeri udio poduzeća koja AI koriste za automatizaciju radnih tokova ili pomoć pri odlučivanju. Stoga se u radu ovaj pokazatelj interpretira kao indikator procesne primjene umjetne inteligencije, a ne kao izravna mjera ekonomskog učinka AI-ja.

# 4. REZULTATI ISTRAŽIVANJA

Rezultati pokazuju da procesna primjena umjetne inteligencije u državama članicama Europske unije raste u razdoblju 2023. – 2025., ali i da je snažno povezana s veličinom poduzeća. Neponderirani prosjek EU-27 pokazuje jasan obrazac (Tablica 2.), mala poduzeća imaju najniže udjele primjene AI-ja za automatizaciju radnih tokova i potporu odlučivanju, srednja poduzeća ostvaruju više vrijednosti, dok su velika poduzeća u svim promatranim godinama znatno ispred ostalih skupina.

**Tablica 2. Neponderirani EU-27 prosjek prema veličini poduzeća, 2023. – 2025.**

| Veličina poduzeća | 2023. | 2024. | 2025. | Promjena 2023. – 2025. |
|---|---|---|---|---|
| Mala, 10–49 | 2,19 | 3,48 | 4,42 | +2,23 postotna boda |
| Srednja, 50–249 | 5,80 | 8,01 | 9,68 | +3,88 postotna boda |
| Velika, 250+ | 16,55 | 21,03 | 24,90 | +8,35 postotna boda |

Izvor: izrada autora prema podacima Eurostata (2026).

Iz Tablice 2. vidljivo je da primjena AI-ja za automatizaciju radnih tokova i potporu odlučivanju raste u svim veličinskim skupinama. Međutim, rast je najizraženiji kod velikih poduzeća, gdje se udio povećao s 16,55% u 2023. na 24,90% u 2025. godini. Kod srednjih poduzeća rast iznosi 3,88 postotnih bodova, dok je kod malih poduzeća rast znatno sporiji i iznosi 2,23 postotna boda. Takav rezultat upućuje na to da se procesna primjena AI-ja širi, ali ne jednakom dinamikom među poduzećima različite veličine.

Usporedba Hrvatske s neponderiranim prosjekom EU-27 pokazuje da Hrvatska u 2025. godini zaostaje u svim veličinskim skupinama poduzeća. Hrvatska ostvaruje 1,70% kod malih poduzeća, 7,11% kod srednjih poduzeća i 19,69% kod velikih poduzeća. U odnosu na neponderirani prosjek EU-27,

to znači negativno odstupanje u svim promatranim skupinama. Sintetski prosjek triju veličinskih skupina koristi se isključivo radi usporednog pozicioniranja država, a ne kao službeni ukupni udio svih poduzeća u gospodarstvu.

**Tablica 3. Hrvatska u odnosu na neponderirani EU-27 prosjek u 2025. godini**

| Veličina poduzeća | EU-27 prosjek | Hrvatska | Razlika HR–EU | Rang Hrvatske |
|---|---|---|---|---|
| Mala, 10–49 | 4,42 | 1,70 | -2,72 postotna boda | 24/27 |
| Srednja, 50–249 | 9,68 | 7,11 | -2,57 postotna boda | 16/27 |
| Velika, 250+ | 24,90 | 19,69 | -5,21 postotna boda | 20/27 |
| Prosjek triju skupina | 13,00 | 9,50 | -3,50 postotna boda | 19/27 |

Izvor: izrada autora prema podacima Eurostata (2026).

Tablica 3. pokazuje da je Hrvatska najbliža prosjeku EU-27 kod srednjih poduzeća, gdje zauzima 16. mjesto među 27 država članica. Kod velikih poduzeća Hrvatska je na 20. mjestu, dok je kod malih poduzeća na 24. mjestu. Iako je apsolutni jaz u postotnim bodovima najveći kod velikih poduzeća, relativno je najnepovoljniji položaj Hrvatske vidljiv kod malih poduzeća. Hrvatska mala poduzeća ostvaruju 1,70%, što iznosi približno 38,5% neponderiranog EU-27 prosjeka za tu skupinu.

Kretanje Hrvatske kroz vrijeme pokazuje da rast primjene AI-ja nije ravnomjerno raspoređen prema veličini poduzeća (Tablica 4.). Dok srednja i velika poduzeća bilježe rast u razdoblju 2023. – 2025., mala poduzeća pokazuju vrlo slab rast i pad u 2025. u odnosu na 2024. godinu.

**Tablica 4. Kretanje Hrvatske prema veličini poduzeća, 2023. – 2025.**

| Veličina poduzeća | 2023. | 2024. | 2025. | Promjena 2023. – 2025. |
|---|---|---|---|---|
| Mala, 10–49 | 1,14 | 2,20 | 1,70 | +0,56 postotna boda |
| Srednja, 50–249 | 4,12 | 6,57 | 7,11 | +2,99 postotna boda |
| Velika, 250+ | 12,61 | 15,70 | 19,69 | +7,08 postotna boda |

Izvor: izrada autora prema podacima Eurostata (2026).

Iz Tablice 4. vidljivo je da rast u Hrvatskoj ponajprije nose velika poduzeća, kod kojih se udio povećao za 7,08 postotnih bodova. Srednja poduzeća također bilježe rast, i to za 2,99 postotnih bodova. Kod malih poduzeća rast je znatno slabiji, a vrijednost iz 2025. niža je od vrijednosti iz 2024. godine. Taj nalaz upućuje na mogućnost da se procesna primjena umjetne inteligencije u Hrvatskoj razvija neravnomjerno te da su mala poduzeća slabije uključena u taj oblik tehnološke primjene.

Veličinski jaz između malih i velikih poduzeća dodatno potvrđuje neravnomjernost procesne primjene AI-ja (Tablica 5.). U 2025. godini neponderirani prosjek EU-27 pokazuje da velika poduzeća koriste AI za automatizaciju radnih tokova i potporu odlučivanju 5,6 puta češće od malih poduzeća. U Hrvatskoj je taj omjer još izraženiji.

**Tablica 5. Veličinski jaz između velikih i malih poduzeća u 2025. godini**

| Jedinica | Mala 2025. | Velika 2025. | Jaz velika–mala | Omjer velika/mala |
|---|---|---|---|---|
| EU-27 prosjek | 4,42 | 24,90 | 20,48 postotna boda | 5,6× |
| Hrvatska | 1,70 | 19,69 | 17,99 postotna boda | 11,6× |

Izvor: izračun autora prema podacima Eurostata (2026).

U Hrvatskoj velika poduzeća koriste AI za automatizaciju radnih tokova i potporu odlučivanju oko 11,6 puta češće od malih poduzeća. Iako je apsolutni jaz između velikih i malih poduzeća u Hrvatskoj nešto manji od neponderiranog prosjeka EU-27, relativni omjer pokazuje znatno izraženiju unutarnju neravnotežu. To je posebno važno za interpretaciju jer pokazuje da slabija pozicija Hrvatske nije samo pitanje ukupnog zaostajanja, nego i pitanje strukture primjene AI-ja među različitim veličinskim skupinama poduzeća.

Statistička analiza potvrđuje da razlike prema veličini poduzeća i promjene kroz vrijeme nisu samo opisne, nego statistički značajne (Tablica 6.). Budući da se za svaku državu članicu uspoređuju tri povezane veličinske skupine poduzeća, za razlike prema veličini korišten je Friedmanov test. Isti test korišten je i za provjeru promjena kroz vrijeme, posebno za svaku veličinsku skupinu poduzeća.

**Tablica 6. Statistička provjera razlika prema veličini poduzeća i promjena kroz vrijeme**

| Dio analize | Usporedba | Test | $\chi^2$ | df | p | Kendall W | Zaključak |
|---|---|---|---|---|---|---|---|
| Razlike prema veličini, 2023. | Mala, srednja, velika poduzeća | Friedman | 5z4,00 | 2 | < 0,001 | 1,00 | Značajne razlike |
| Razlike prema veličini, 2024. | Mala, srednja, velika poduzeća | Friedman | 54,00 | 2 | < 0,001 | 1,00 | Značajne razlike |
| Razlike prema veličini, 2025. | Mala, srednja, velika poduzeća | Friedman | 54,00 | 2 | < 0,001 | 1,00 | Značajne razlike |
| Promjene kroz vrijeme – mala | 2023., 2024., 2025. | Friedman | 40,22 | 2 | < 0,001 | 0,74 | Značajne promjene |
| Promjene kroz vrijeme – srednja | 2023., 2024., 2025. | Friedman | 36,74 | 2 | < 0,001 | 0,68 | Značajne promjene |
| Promjene kroz vrijeme – velika | 2023., 2024., 2025. | Friedman | 48,67 | 2 | < 0,001 | 0,90 | Značajne promjene |

Izvor: izračun autora prema podacima Eurostata (2026).

Rezultati Friedmanova testa pokazuju da su razlike između malih, srednjih i velikih poduzeća statistički značajne u svim promatranim godinama. Vrijednost Kendallova W iznosi 1,00, što upućuje na potpunu konzistentnost poretka veličinskih skupina: u svim državama i svim godinama velika poduzeća ostvaruju višu razinu primjene AI-ja od srednjih, a srednja višu razinu od malih poduzeća.

Dodatne parne usporedbe Wilcoxonovim testovima potvrđuju da su razlike između svih veličinskih skupina statistički značajne na razini $p < 0,001$. To vrijedi za usporedbe srednjih i malih poduzeća, velikih i srednjih poduzeća te

velikih i malih poduzeća. Time se potvrđuje da se razina procesne primjene umjetne inteligencije statistički značajno razlikuje prema veličini poduzeća.

Friedmanov test za promjene kroz vrijeme pokazuje da su promjene u razdoblju 2023. – 2025. statistički značajne za mala, srednja i velika poduzeća. Najsnažniji i najkonzistentniji učinak vidljiv je kod velikih poduzeća, gdje Kendallov W iznosi 0,90. U kombinaciji s deskriptivnim rezultatima, nalazi statističkih testova podupiru zaključak da procesna primjena AI-ja raste kroz vrijeme te da je rast najizraženiji kod velikih poduzeća.

Na temelju deskriptivnih i statističkih rezultata može se zaključiti da su potvrđene sve četiri hipoteze rada. Prva hipoteza potvrđena je jer velika poduzeća u svim promatranim godinama i državama ostvaruju više vrijednosti od srednjih i malih poduzeća. Druga hipoteza potvrđena je jer se primjena AI-ja povećava u razdoblju 2023. – 2025. Treća hipoteza potvrđena je jer Hrvatska u 2025. zaostaje za neponderiranim prosjekom EU-27 u svim veličinskim skupinama. Četvrta hipoteza potvrđena je uz dodatno preciziranje: relativno zaostajanje Hrvatske najizraženije je kod malih poduzeća, dok je apsolutni jaz u postotnim bodovima najveći kod velikih poduzeća.

## 5. DISKUSIJA

Rezultati istraživanja pokazuju da se procesna primjena umjetne inteligencije značajno razlikuje među poduzećima različite veličine. Konkretno, velika poduzeća u svim promatranim godinama i državama članicama EU-a češće koriste AI za automatizaciju radnih tokova i potporu odlučivanju od srednjih i malih poduzeća. Taj nalaz podupire hipotezu H1 o većoj zastupljenosti procesne primjene AI-ja u velikim poduzećima u odnosu na srednja i mala poduzeća. Time se potvrđuju rezultati koje iznose Schwaeke i suradnici (2025), prema kojima mala i srednja poduzeća nemaju jednake kapacitete za usvajanje umjetne inteligencije kao velika poduzeća. Nadalje, potvrđeni su i zaključci koje navode Oldemeyer i suradnici (2025), prema kojima su izazovi primjene AI-ja u manjim poduzećima povezani s dostupnošću podataka, kompetencijama, resursima i razumijevanjem mogućnosti tehnologije. Istodobno, utvrđene promjene kroz vrijeme, zajedno s rastom prosječnih vrijednosti u promatranom razdoblju, podupiru hipotezu H2.

Razlike prema veličini poduzeća ipak ne treba tumačiti isključivo kao posljedicu razlika u organizacijskim kapacitetima. Budući da analiza ne kontrolira sektorsku strukturu niti karakter poslovnih procesa, dio utvrđenih razlika može proizlaziti i iz različite potrebe za automatizacijom radnih tokova i potporom odlučivanju među djelatnostima i vrstama poduzeća.

Arroyabe i suradnici (2024) pokazuju da usvajanje AI-ja u europskim malim i srednjim poduzećima ovisi o digitalnim sposobnostima, inovacijskim kapacitetima i vanjskom okruženju, a rezultati ovoga rada nadovezuju se na taj zaključak jer pokazuju da se AI za automatizaciju radnih tokova i potporu odlučivanju znatno češće koristi u većim poduzećima. Pritom rezultati ovog rada ne omogućuju izravnu usporedbu opće i procesne uporabe umjetne inteligencije jer opća uporaba nije uključena u empirijsku analizu. Rezultati su u skladu i s pristupom koji iznose Kumar i suradnici (2025), prema kojem poslovnu vrijednost AI-ja treba promatrati kroz stvarnu uporabu, organizacijsku prilagodbu i stvaranje koristi u konkretnim radnim situacijama.

Hrvatska u 2025. godini zaostaje za prosjekom EU-27 u svim veličinskim skupinama poduzeća, ali je relativno najnepovoljniji položaj vidljiv kod malih poduzeća. Zaostajanje Hrvatske u svim veličinskim skupinama podupire hipotezu H3, dok relativno najnepovoljniji položaj malih poduzeća podupire hipotezu H4. Taj nalaz podupire zaključke koje navode Rajaram i Tinguely (2024), prema kojima mala i srednja poduzeća mogu imati koristi od generativne umjetne inteligencije, ali se suočavaju s ograničenjima u znanju, resursima, upravljanju rizicima i sposobnosti integracije AI-ja u svakodnevne aktivnosti. U kombinaciji s nalazima navedene literature, rezultati za Hrvatsku upućuju na potrebu jačanja podatkovne infrastrukture, digitalnih kompetencija, savjetodavne potpore, upravljačke svijesti i organizacijske spremnosti, osobito kod malih poduzeća.

# 6. ZAKLJUČAK

Cilj rada bio je analizirati postoje li razlike u primjeni umjetne inteligencije za automatizaciju radnih tokova i potporu odlučivanju prema veličini poduzeća te utvrditi položaj Hrvatske u odnosu na neponderirani prosjek EU-27. Rezultati pokazuju da procesna primjena AI-ja u državama članicama Europske unije raste u razdoblju 2023. – 2025., ali da je snažno povezana s veličinom poduzeća. Velika poduzeća u svim promatranim godinama i

državama članicama ostvaruju više vrijednosti od srednjih i malih poduzeća, čime je potvrđena prva hipoteza. Statistički značajan rast kroz vrijeme potvrđuje drugu hipotezu, dok podaci za Hrvatsku potvrđuju treću hipotezu jer Hrvatska u 2025. godini zaostaje za neponderiranim prosjekom EU-27 u svim veličinskim skupinama poduzeća. Četvrta hipoteza potvrđena je uz dodatno preciziranje, relativno zaostajanje Hrvatske najizraženije je kod malih poduzeća, iako je apsolutni jaz u postotnim bodovima najveći kod velikih poduzeća.

Rezultati rada pokazuju da je procesna primjena umjetne inteligencije povezana s veličinom poduzeća te da među veličinskim skupinama postoje izražene razlike u zastupljenosti uporabe AI-ja za automatizaciju radnih tokova i potporu odlučivanju. U hrvatskom kontekstu osobito je važno to što mala poduzeća ostvaruju najnepovoljniji relativni položaj u odnosu na prosjek EU-27. U kombinaciji s nalazima prethodnih istraživanja, takav rezultat upućuje na potrebu ciljanog jačanja podatkovne infrastrukture, digitalnih kompetencija, savjetodavne potpore i upravljačke svijesti, posebno u segmentu malih poduzeća. Aplikativna vrijednost rada proizlazi iz mogućnosti korištenja rezultata kao podloge za oblikovanje mjera koje potiču ne samo usvajanje AI tehnologija, nego i njihovu primjenu u konkretnim organizacijskim procesima. Takvo polazište osobito je važno za javne politike i poslovno odlučivanje jer usmjerava pozornost s opće prisutnosti AI tehnologija prema njihovu korištenju u radnim tokovima i odlučivanju.

Ograničenje istraživanja proizlazi iz činjenice da se analiza temelji na jednom glavnom Eurostat pokazatelju, koji ne mjeri izravno produktivnost, profitabilnost ni poslovnu vrijednost umjetne inteligencije, nego udio poduzeća koja AI koriste za automatizaciju radnih tokova i pomoć pri odlučivanju. Dodatno, EU-27 prosjek u radu je neponderirani prosjek država članica, što je prikladno za komparaciju država, ali ne predstavlja službeni ponderirani agregat svih poduzeća u Europskoj uniji. Nadalje, dodatno ograničenje proizlazi iz činjenice da su veličinske skupine poduzeća definirane brojem zaposlenih, pa promjene zaposlenosti kroz vrijeme mogu dovesti do prelaska pojedinih poduzeća iz jedne veličinske skupine u drugu. Budući da se analiza temelji na agregiranim podacima, nije moguće pratiti ista poduzeća kroz promatrano razdoblje. Analiza također ne kontrolira sektorsku strukturu poduzeća, pa se utvrđene razlike prema veličini ne mogu pripisati isključivo razlikama u resursima ili organizacijskim kapacitetima. Buduća istraživanja mogla bi proširiti analizu na opću uporabu AI-ja, sektorske razlike, pokazatelje produktivnosti, digitalni intenzitet poduzeća,

podatkovnu zrelost i druge pokazatelje AI spremnosti, čime bi se dobio potpuniji uvid u odnos između procesne primjene umjetne inteligencije i stvaranja poslovne vrijednosti.

# LITERATURA

Arroyabe, M. F., Arranz, C. F. A., Fernandez de Arroyabe, I. i Fernandez de Arroyabe, J. C. (2024). Analyzing AI adoption in European SMEs: A study of digital capabilities, innovation, and external environment. Technology in Society, 79, 102733. https://doi.org/10.1016/j.techsoc.2024.102733

Conover, W. J. (1999). Practical Nonparametric Statistics (3. izd.). New York: John Wiley & Sons.

Corder, G. W. i Foreman, D. I. (2011). Nonparametric Statistics for Non-Statisticians: A Step-by-Step Approach. Hoboken, NJ: John Wiley & Sons.

D'Amico, E., Audretsch, D. B., Belitski, M. i Colombelli, A. (2026). Adopting artificial intelligence in small and medium businesses: The knowledge-based perspective. Small Business Economics, 67, 1019-1045. https://doi.org/10.1007/s11187-026-01214-7

Eurostat. (2026). Artificial intelligence by size class of enterprise [skup podataka]. Online data code: isoc_eb_ai. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/isoc_eb_ai/default/table?lang=en

Hollander, M., Wolfe, D. A. i Chicken, E. (2013). Nonparametric Statistical Methods (3. izd.). Hoboken, NJ: John Wiley & Sons.

ISO/IEC. (2023). ISO/IEC 42001:2023 Information technology – Artificial intelligence – Management system. Međunarodna organizacija za normizaciju i Međunarodno elektrotehničko povjerenstvo.

Jajić, I. (2026, 20. travnja). Od hypea do vrijednosti: Okvir za procjenu poslovne opravdanosti i upravljanje ulaganjima u umjetnu inteligenciju na razini uprave i nadzornog odbora. CCGM – Hrvatsko društvo za korporativno upravljanje i menadžment. Dostupno na: https://ccgm.hr/od-hypea-do-vrijednosti-okvir-za-procjenu-poslovne-opravdanosti-i-upravljanje-ulaganjima-u-umjetnu-inteligenciju-na-razini-uprave-i-nadzornog-odbora/

Kumar, A., Shankar, A., Hollebeek, L. D., Behl, A. i Lim, W. M. (2025). Generative artificial intelligence (GenAI) revolution: A deep dive into GenAI adoption. Journal of Business Research, 189, 115160. https://doi.org/10.1016/j.jbusres.2024.115160

National Institute of Standards and Technology. (2023). Artificial Intelligence Risk Management Framework (AI RMF 1.0). NIST AI 100-1. U.S. Department of Commerce. https://doi.org/10.6028/NIST.AI.100-1

Novelli, C., Taddeo, M. i Floridi, L. (2024). Accountability in artificial intelligence: What it is and how it works. AI & Society, 39(4), 1871-1882. https://doi.org/10.1007/s00146-023-01635-y

OECD. (2024). Framework for anticipatory governance of emerging technologies. OECD Science, Technology and Industry Policy Papers, No. 165. OECD Publishing. https://doi.org/10.1787/0248ead5-en

Oldemeyer, L., Jede, A. i Teuteberg, F. (2025). Investigation of artificial intelligence in SMEs: A systematic review of the state of the art and the main implementation challenges. Management Review Quarterly, 75(2), 1185-1227. https://doi.org/10.1007/s11301-024-00405-4

Polisetty, A., Chakraborty, D., G, S., Kar, A. K. i Pahari, S. (2024). What determines AI adoption in companies? Mixed-method evidence. Journal of Computer Information Systems, 64(3), 370-387. https://doi.org/10.1080/08874417.2023.2219668

Rajaram, K. i 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

Rana, N. P., Pillai, R., Sivathanu, B. i Malik, N. (2024). Assessing the nexus of generative AI adoption, ethical considerations and organizational performance. Technovation, 135, 103064. https://doi.org/10.1016/j.technovation.2024.103064

Schwaeke, J., Peters, A., Kanbach, D. K., Kraus, S. i Jones, P. (2025). The new normal: The status quo of AI adoption in SMEs. Journal of Small Business Management, 63(3), 1297-1331. https://doi.org/10.1080/00472778.2024.2379999

Singla, A., Sukharevsky, A., Yee, L., Chui, M. i Hall, B. (2025). The state of AI: How organizations are rewiring to capture value. McKinsey & Company. Dostupno na: https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai-how-organizations-are-rewiring-to-capture-value

Tipurić, D. (2025). Morocracy. Ekonomski pregled, 76(6), 482-502. https://doi.org/10.32910/ep.76.6.5

Tušek, B., Ježovita, A. i Halar, P. (2018). Perspektive razvoja i izazovi funkcije interne revizije u eri digitalne transformacije poslovanja. Zbornik radova Ekonomskog fakulteta Sveučilišta u Mostaru, 24, 258-288. https://doi.org/10.46458/27121097.2018.24.229

# PROCESS-ORIENTED USE OF ARTIFICIAL INTELLIGENCE IN ENTERPRISES: A COMPARISON OF CROATIA AND THE EUROPEAN UNION BY ENTERPRISE SIZE

***Abstract***

*The objective of this paper is to conduct an analysis of process-oriented application of artificial intelligence (AI) based on enterprise size and the positioning of Croatia compared to the unweighted average of European Union Member States. For this purpose, process-oriented application means the use of AI technologies for workflow automation or decision-making support purposes. Eurostat data are used, including the period 2023-2025, and cover 27 EU Member States (EU-27) classified by enterprise size. Methods of descriptive and comparative analysis, gap analysis, Friedman test, and Wilcoxon tests are applied. According to the findings, the use of process-oriented AI technologies grew during the studied period, differing considerably depending on enterprise size. Also, Croatia ranks below the unweighted EU-27 average in all enterprise size categories, being the most disadvantaged in relation to small enterprises. The main limitation of the research results is related to the fact that only one indicator is considered, which does not directly measure productivity or business value. The novelty of the paper is related to the empirical analysis of the process-oriented use of AI based on enterprise size and comparative positioning of Croatia.*

***Keywords:*** *artificial intelligence, workflow automation, decision support, enterprises, Croatia, EU-27.*

JEL klasifikacija: J24, O33, J23
Prethodno priopćenje

# IZLOŽENOST POSLOVNIH I EKONOMSKIH ZANIMANJA GENERATIVNOJ UMJETNOJ INTELIGENCIJI: ANALIZA NA RAZINI RADNIH ZADATAKA S OSVRTOM NA HRVATSKO TRŽIŠTE RADA

Mia Despotović *
Stella Antolović **
Rosa Stojnić***

## SAŽETAK

Konvencionalne procjene izloženosti tržišta rada generativnoj umjetnoj inteligenciji u pravilu se provode na razini zanimanja. Ovaj rad preispituje navedeni pristup te istražuje predstavlja li izloženost poslovnih i ekonomskih zanimanja homogeno svojstvo samih zanimanja ili heterogeno obilježje

* Dr. sc. Mia Despotović, Sveučilište Algebra Bernays, vanjska suradnica (e-mail: mia.despotovic@gmail.com), korespondirajući autor.
** Stella Antolović, Sveučilište Algebra Bernays, viša predavačica (e-mail: stella.antolovic@algebra.hr).
*** Rosa Stojnić, 7Sense Digital d.o.o., suosnivačica (e-mail: r.stojnic@gmail.com).

pripadajućih radnih zadataka. Empirijska analiza obuhvaća 22 zanimanja unutar osam poslovnih područja (ukupno 429 zadataka), jednoznačno mapiranih između klasifikacijskih sustava O*NET-SOC, ISCO-08 i ESCO. Primarna mjera izloženosti jest GPT-4 beta, a mjera Artificial Intelligence Occupational Exposure (AIOE) koristi se kao dopunska deskriptivna mjera. Pet hipoteza testirano je Kruskal-Wallisovim testom, jednosmjernom analizom varijance i njezinom dekompozicijom ($\eta^2$, ICC(1)), linearnom regresijom, Mann-Whitneyjevim U-testom i Pearsonovom korelacijom. Dekompozicija varijance pokazuje da pripadnost zanimanju objašnjava svega 15,5 % ukupne varijance izloženosti, dok preostalih 84,5 % proizlazi iz razlika među zadacima unutar istoga zanimanja. Informacijsko-analitički zadaci pritom bilježe značajno višu izloženost od interpersonalnih. Razlike u izloženosti među poslovnim područjima statistički su značajne na razini radnih zadataka, ali ne i na razini zanimanja. Istodobno, usporedba strukture zaposlenosti Republike Hrvatske i Sjedinjenih Američkih Država daje gotovo jednake ponderirane prosjeke izloženosti, što upućuje na neosjetljivost prosjeka na kompoziciju zaposlenosti, a ne na strukturnu sličnost dvaju tržišta. Zaposlenost u skupinama poslova visoko izloženim generativnoj umjetnoj inteligenciji od 2016. do 2025. godine kretala se nejednoliko i po skupinama i tijekom vremena. Nalazi upućuju na to da visoka učilišta ishode učenja trebaju usmjeravati prema tipovima zadataka, a ne prema popisima zanimanja izloženih riziku umjetne inteligencije. Ograničenja istraživanja proizlaze iz klasifikacije zadataka ključnim riječima, malog uzorka zanimanja i agregiranosti podataka. Doprinos rada očituje se u dekompoziciji varijance koja pokazuje da je izloženost ponajprije obilježje pojedinačnog zadatka, a ne zanimanja kao cjeline, te u prikazu strukture hrvatske zaposlenosti na dvoznamenkastoj razini ISCO-08.

**Ključne riječi:** generativna umjetna inteligencija, izloženost zanimanja, radni zadaci, tržište rada, visoko obrazovanje.

## 1. UVODNA RAZMATRANJA

Brzina integracije generativne umjetne inteligencije na radnim mjestima mijenja ekonomsku vrijednost visokog obrazovanja. Podaci koje navode Bick, Blandin i Deming (2024) pokazuju da je sredinom 2024. godine gotovo 40 % radno sposobnog stanovništva SAD-a koristilo se ovom tehnologijom, dok se njome gotovo četvrtina zaposlenih (23 %) koristila na poslu barem jednom u prethodnom tjednu. S obzirom na to da su poslovi u financijama,

računovodstvu, marketingu i poslovnoj analitici primarno utemeljeni na obradi informacija, oni čine važnu apsorpcijsku bazu za diplomante ekonomije. Visoka podložnost ovih zanimanja automatizaciji implicira da tehnološki šok izravno devalvira tradicionalne ekonomske kurikulume, potencijalno generirajući strukturni nesklad između vještina koje isporučuju i onih koje novo tržište traži.

Makroekonomske procjene globalnih razmjera utjecaja ovoga tehnološkog vala potvrđuju dubinu strukturnih promjena, ali i otvaraju važne metodološke rasprave. Eloundou i sur. (2024) procjenjuju da bi 80 % radne snage u SAD-u moglo osjetiti utjecaj velikih jezičnih modela na najmanje desetinu zadataka, uz progresivan rast izloženosti s visinom dohotka. Na globalnoj razini Cazzaniga i sur. (2024) procjenjuju izravnu izloženost umjetnoj inteligenciji na 60 % zaposlenosti u razvijenim gospodarstvima. Nasuprot pesimističnim scenarijima, Međunarodna organizacija rada sugerira da će dominantan učinak tehnologije biti augmentacija, a ne supstitucija rada (Gmyrek, Berg i Bescond, 2023), što podupiru i rane empirijske provjere na razini poduzeća (Humlum i Vestergaard, 2025).

Bitan nedostatak spomenutih procjena proizlazi iz pretpostavke o homogenoj izloženosti na razini zanimanja. Suvremeni teorijski pristup utemeljen na zadacima (engl. *task-based approach*) upozorava da tehnološki supstituti ne djeluju na zanimanja kao nedjeljive cjeline, nego dekonstruiraju specifične zadatke unutar njih (Acemoglu i Autor, 2011; Acemoglu i Restrepo, 2019). Uvažavanje te heterogenosti mijenja analitičke ishode. Dok su Frey i Osborne (2017) na razini zanimanja procijenili da je 47 % radnih mjesta pod visokim rizikom automatizacije, Arntz, Gregory i Zierahn (2016) unutar zemalja OECD-a dolaze do stope od svega 9 %. Za poslovna i ekonomska zanimanja, koja karakterizira kompleksno prožimanje informacijskih i interpersonalnih zadataka, posljedično se postavlja pitanje: koliki dio izloženosti proizlazi iz prirode zanimanja, a koliki iz heterogenosti zadataka unutar pojedine skupine?

Slijedom navedenog, svrha je ovog rada dvojaka. Prvo, na uzorku od 22 poslovna i ekonomska zanimanja te 429 pripadajućih zadataka rad testira pet hipoteza o čimbenicima koji uvjetuju razlike u izloženosti generativnoj umjetnoj inteligenciji. Drugo, rad uspoređuje strukturu zaposlenosti u Hrvatskoj s onom u Sjedinjenim Američkim Državama kroz prizmu tih pokazatelja, implementirajući ih u analizu trenda domaće zaposlenosti od 2016. do 2025. godine. U pogledu strukture, nakon uvodnih razmatranja, drugo poglavlje dekonstruira teorijski okvir i daje kritički pregled relevantne

literature. Nakon teorijskoga okvira i metodologije, rad donosi empirijske rezultate, ekonomsku interpretaciju te zaključne implikacije.

# 2. TEORIJSKI OKVIR I PREGLED LITERATURE

## 2.1. Pristup utemeljen na zadacima i mjerenje izloženosti

Teorijsko polazište analize čini model koji su razvili Autor, Levy i Murnane (2003), prema kojemu tehnologija zamjenjuje rad u rutinskim, a nadopunjuje ga u nerutinskim zadacima. Acemoglu i Autor (2011) formaliziraju razliku između vještina i zadataka, dok Acemoglu i Restrepo (2019) dekonstruiraju učinak automatizacije na supstituciju radne snage, rast produktivnosti i stvaranje novih zadataka. Autor (2015) naglašava da suvremena tehnologija povećava komparativnu prednost radnika u procesima koji zahtijevaju prosudbu i prilagodljivost. Empirijska provjera na 18.156 zadataka koju su proveli Brynjolfsson, Mitchell i Rock (2018) nadalje potvrđuje da automatizacija zahtijeva preoblikovanje sadržaja radnoga mjesta, dok Acemoglu (2025) ističe da budući učinci tehnologije ovise o specifičnom kontekstu u kojem se ti zadaci obavljaju. Temeljna je pretpostavka da je izloženost inherentno svojstvo zadatka, a ne zanimanja.

Mjere izloženosti razvijale su se od procjena same vjerojatnosti automatizacije prema pokazateljima koji su neutralni glede smjera tehnološkog učinka. Felten, Raj i Seamans (2021) oblikuju mjeru AIOE, agnostičnu prema supstituciji ili komplementarnosti, koja upućuje na izraženiji utjecaj umjetne inteligencije na zanimanja visokog kognitivnog intenziteta. Za velike jezične modele Eloundou i sur. (2024) razvijaju rubriku vremenskog skraćenja izvršenja zadataka uz očuvanje kvalitete, dok Felten, Raj i Seamans (2023) prilagođavaju AIOE jezičnom modeliranju.

Analiza relevantne literature upućuje na dva ključna metodološka obilježja važna za ovaj rad. S jedne strane, primarni pokazatelji počivaju na američkom sustavu O*NET-SOC, što implicira nužnost njihova prevođenja na europske standarde ISCO-08 (engl. *International Standard Classification of Occupations*) i ESCO (engl. *European Skills, Competences, Qualifications and Occupations*). S druge strane, rezultati se uglavnom agregiraju i prikazuju kao prosjeci zanimanja. Takav pristup zanemaruje varijaciju zadataka unutar samih zanimanja, unatoč tome što pojedini indeksi, primjerice onaj autora Eloundou i sur. (2024), inicijalno nastaju na razini specifičnih zadataka.

## 2.2. Empirijski dokazi o generativnoj umjetnoj inteligenciji i istraživački jaz

Eksperimentalna istraživanja potvrđuju heterogenost učinaka generativne umjetne inteligencije na razini zadataka. Noy i Zhang (2023) utvrđuju da ChatGPT skraćuje vrijeme profesionalnih pisanih zadataka za 40 % uz povećanje kvalitete za 18 %, dok Brynjolfsson, Li i Raymond (2025) kod agenata korisničke podrške bilježe rast produktivnosti od 15 %, ponajprije osnaživanjem manje iskusne radne snage. Dell'Acqua i sur. (2023) konceptom tzv. *nazubljene tehnološke granice* (engl. *jagged technological frontier*) pokazuju da su konzultanti s pristupom GPT-4 bili 25,1 % brži u izvršenju zadataka unutar tehnološkog dosega, ali je točnost izvršenja kompleksnih menadžerskih zadataka izvan te granice bila niža za 19 postotnih bodova.

Makroekonomski dokazi s tržišta rada i dalje su podijeljeni. Dok Hui, Reshef i Zhou (2024) bilježe pad zaposlenosti i zarada slobodnih profesija na *online* platformama izloženim ovom valu inovacija, Humlum i Vestergaard (2025) na danskim administrativnim podacima prate široku difuziju generativnih AI asistenata i oblikovanje novih zadataka. Međutim, potonji autori utvrđuju nulte učinke na ukupne zarade i radne sate dvije godine nakon uvođenja ChatGPT-a, što sugerira da se dosadašnji učinci primarno očituju u restrukturiranju radnih zadataka unutar zanimanja.

Pregled literature otkriva tri ključna metodološka nedostatka. Prvo, prevladavajuće procjene zanemaruju teorijske modele analizirajući zanimanja umjesto zadataka, zbog čega dekompozicija varijance izloženosti unutar analiziranih segmenata zanimanja dosada nije provedena. Drugo, pretpostavka o neutralnosti interpersonalnih zadataka spram informacijsko-analitičkih šokova rijetko se podvrgava izravnoj provjeri unutar istog uzorka. Treće, za hrvatsko gospodarstvo ne postoje sustavne procjene izloženosti, što je primarno posljedica visoko agregirane strukture službenih statističkih podataka o radnoj snazi.

# 3. METODOLOGIJA, EMPIRIJSKI REZULTATI I INTERPRETACIJA

## 3.1. Metodologija istraživanja

Empirijska analiza testira pretpostavku o asimetričnoj izloženosti poslovnih i ekonomskih zanimanja generativnoj umjetnoj inteligenciji na tri hijerarhijske

razine. Unutar osam širih poslovnih domena promatraju se 22 zanimanja koja se u najdetaljnijoj analitičkoj matrici dekonstruiraju na 429 specifičnih radnih zadataka. Temeljna je premisa istraživanja da tehnološka izloženost nije funkcija formalne klasifikacije zanimanja, nego stvarnog sadržaja pripadajućih zadataka. Slijedom navedenog, ako je izloženost inherentno svojstvo strukture zadataka, a ne samog zanimanja, varijacija između zanimanja i širih poslovnih domena trebala bi biti zanemariva u usporedbi s varijacijom među zadacima unutar zanimanja. Hipoteze $H_{1a}$ i $H_{1b}$ formalizirane su radi provjere ove zakonitosti, pri čemu njihovo statističko odbacivanje izravno podupire teorijski pristup utemeljen na zadacima.

S obzirom na to da konstruirani indeksi imaju dvostruko ugniježđenu strukturu, prva se hipoteza operacionalizira dvjema pothipotezama, specifičnima za pojedinu razinu agregacije:

**$H_{1a}$**: Poslovne se domene razlikuju u prosječnoj izloženosti na agregiranoj razini zanimanja (testira se Kruskal-Wallisovim testom).

**$H_{1b}$**: Poslovne se domene razlikuju u prosječnoj izloženosti na dezagregiranoj razini radnih zadataka (testira se jednosmjernom analizom varijance).

**$H_2$**: Zanimanja s većim udjelom informacijsko-analitičkih zadataka bilježe višu prosječnu izloženost.

**$H_3$**: Unutar istoga zanimanja postoji značajna varijabilnost izloženosti među zadacima.

**$H_4$**: Interpersonalni i prosudbeni zadaci manje su izloženi tehnološkom učinku od zadataka obrade informacija.

**$H_5$**: Zanimanja s višom prosječnom izloženošću pokazuju veću heterogenost unutar zanimanja.

Zanimanja su odabrana prema kriteriju jednoznačnog mapiranja između triju klasifikacijskih sustava koji se koriste u radu: američkog O*NET-SOC sustava, europskog ISCO-08 sustava te ESCO nomenklature. Time je iz uzorka namjerno isključen manji broj zanimanja kod kojih ne postoji jednoznačan ekvivalent u sva tri sustava, a čije bi uključivanje unijelo mjernu pogrešku.

U svrhu operacionalizacije mjerenja izloženosti generativnoj umjetnoj inteligenciji u radu se koriste dvije metodološki različite mjere s različitim ulogama u analizi. Prva je mjera GPT-4 beta (Eloundou i sur., 2024), pri čemu

$\beta$ označava shemu ponderiranja definiranu kao $\beta = E_1 + 0{,}5 \cdot E_2$. Kategorija $E_1$ obuhvaća zadatke kojima izravan pristup velikom jezičnom modelu prepolovljuje vrijeme izvršenja uz zadržanu kvalitetu ishoda, a kategorija $E_2$ zadatke kod kojih je za isti učinak potreban dodatni softverski sloj, zbog čega im se pripisuje polovična težina. Druga je mjera AIOE (Felten i sur., 2021, 2023), koja evaluira relativnu izloženost profila ljudskih sposobnosti (engl. *abilities*) izraženu standardiziranim *z*-rezultatom.

Budući da je metrika AIOE ograničena na deskriptivni prikaz i usporedbu zaposlenosti, ekonometrijsko testiranje svih hipoteza utemeljeno je na mjeri GPT-4 beta. Uvažavanjem ograničenja da izvorna O*NET baza podataka ne sadrži unaprijed definiranu klasifikaciju radnih zadataka, njihovo je razvrstavanje na informacijsko-analitičke i interpersonalne provedeno metodom pretraživanja ključnih riječi unutar tekstualnih opisa zadataka. Informacijsko-analitička kategorija obuhvatila je zadatke u kojima dominiraju glagoli poput analizirati, izraditi, izračunati, ocijeniti i dokumentirati. Interpersonalna kategorija je pak definirana kroz glagole kao što su koordinirati, nadzirati, pregovarati, obučavati i savjetovati se. Ovakav je pristup odabran kao namjerno konzervativan i metodološki transparentan okvir za inicijalnu analizu. Ipak, s obzirom na to da automatizirano pretraživanje ključnih riječi ne može u potpunosti obuhvatiti dubinski semantički kontekst, u budućim se istraživanjima preporučuje primjena dvostrukoga neovisnog ručnog kodiranja uz izračun koeficijenta međusobnog slaganja ili primjena LLM-potpomognute klasifikacije uz naknadnu ljudsku validaciju uzorka.

Zadaci su razvrstani u četiri kategorije: informacijsko-analitički (n = 173), interpersonalni (n = 61), mješoviti, koji zadovoljavaju kriterije obiju prethodnih kategorija (n = 24), te ostali, koji ne zadovoljavaju kriterije nijedne (n = 171). Testiranje hipoteze $H_4$ provedeno je samo na informacijsko-analitičkim i interpersonalnim zadacima (n = 234).

### *3.1.1. Dvorazinski istraživački dizajn i deskriptivna usporedba tržišta rada*

Oba su indikatora izloženosti (GPT-4 beta i AIOE) konstruirana na američkim podacima i u ovom se radu primjenjuju na hrvatski kontekst bez provjere valjanosti. Cilj je utvrditi proizlazi li izmjerena tehnološka izloženost

iz strukture radnih zadataka ili je ona refleksija specifičnosti američkog tržišta rada. U tu je svrhu istraživanje strukturirano na dvije analitičke razine.

Prva razina obuhvaća formalno testiranje svih pet postavljenih hipoteza ($H_1$–$H_5$) na razini zanimanja i zadataka na američkim podacima (O*NET-SOC klasifikacija, Eloundou i sur., 2024; Felten i sur., 2021, 2023), budući da visoka granuliranost podataka potrebna za ispitivanje varijabilnosti unutar samih zanimanja ($H_3$, $H_5$) i specifičnih kategorija zadataka ($H_2$, $H_4$) nije dostupna u javno objavljenim europskim ili hrvatskim statističkim izvorima.

Druga razina analize služi kao deskriptivna usporedba strukture zaposlenosti te kao samostalan deskriptivni uvid u kretanja na domaćem tržištu rada. Razina se oslanja na podatke Eurostatove Ankete o radnoj snazi (EU-LFS) za Republiku Hrvatsku, dostupne na razini dvoznamenkaste ISCO-08 klasifikacije za razdoblje od 2016. do 2025. godine.

Povezivanje ovih dviju razina provedeno je mapiranjem zajedničkog popisa od 22 zanimanja iz uzorka, pri čemu je svako zanimanje paralelno kodirano unutar O*NET-SOC sustava (za povezivanje s američkim podacima o izloženosti) i ISCO-08 sustava (za povezivanje s Eurostatovim podacima o zaposlenosti). Važno je naglasiti da se ove baze podataka metodološki ne integriraju u jedinstvenu tablicu na razini pojedinačnog zanimanja. Podaci o izloženosti i podaci o zaposlenosti povezani su isključivo konceptualno, preko naziva zanimanja. Slijedom toga, druga razina ne sudjeluje u testiranju hipoteza $H_1$–$H_5$, već je njezina funkcija ograničena na deskriptivnu usporedbu strukture zaposlenosti i analizu trendova.

Glavno metodološko ograničenje druge razine analize proizlazi iz same naravi podataka Eurostata, koji su javno dostupni isključivo na visokoj razini agregacije. Nasuprot tome, američki izvori (BLS) omogućuju izravan uvid u podatke na razini pojedinačnih zanimanja. Zbog toga se čak devet od 22 zanimanja iz uzorka (stručnjak za marketing, stručnjak za odnose s javnošću, financijski analitičar, računovođa, analitičar proračuna, poslovni analitičar, stručnjak za ljudske potencijale, specijalist za obuku i razvoj te specijalist za poslovne operacije) svrstava u jednu zajedničku skupinu: *Stručnjaci za poslovanje i upravljanje* (ISCO 24). Zaposlenost se posljedično za ova zanimanja ne utvrđuje pojedinačno, već na razini skupine.

Empirijska provjera hipoteza oslanja se na Kruskal-Wallisov test i jednosmjernu analizu varijance (ANOVA) za ispitivanje razlika među poslovnim domenama na razini zanimanja i zadataka. Veza izloženosti i

udjela informacijskih zadataka procijenjena je linearnom regresijom, dok je varijabilnost unutar zanimanja procijenjena ugniježđenom analizom varijance uz izračun pokazatelja $\eta^2$ i ICC(1). Razlike između informacijsko-analitičkih i interpersonalnih zadataka testirane su Mann-Whitneyjevim U-testom, a suodnos prosječne izloženosti i pripadajuće standardne devijacije Pearsonovim koeficijentom korelacije. Sekundarni podaci integriraju taksonomije O*NET, ESCO i ISCO-08, repozitorije Eloundou i sur. (2024) i AIOE te statističke serije zavoda BLS, ILOSTAT i Eurostat (EU-LFS). Izračuni su provedeni u programskom jeziku Python, uz uporabu paketa SciPy i statsmodels, čime je osigurana ponovljivost postupka.

Svi podaci korišteni u analizi prikupljeni su iz javno dostupnih sekundarnih izvora: klasifikacija zanimanja i zadataka O*NET, ESCO i ISCO-08, baze podataka Eloundou i sur. (2024) dostupne putem javnog repozitorija na GitHubu, baze AIOE autora Feltena, Raja i Seamansa, podataka o zaposlenosti Ureda za statistiku rada Sjedinjenih Američkih Država (BLS OEWS) i ILOSTAT-a te Eurostatove Ankete o radnoj snazi za Republiku Hrvatsku. Za sve statističke izračune korišten je programski jezik Python s bibliotekama SciPy i statsmodels.

**Tablica 1. Zanimanja u uzorku (n = 22), šifre klasifikacija i mjere izloženosti**

| Naziv zanimanja | O*NET-SOC | ISCO-08 | ESCO | n | GPT-4 β | SD | Izl. zanim. | AIOE (z) | Udio inf. |
|---|---|---|---|---|---|---|---|---|---|
| aktuar | 15-2011.00 | 2120 | 3314.1 | 15 | 0,500 | 0,000 | 0,500 | 1,516 | 0,20 |
| ekonomist | 19-3011.00 | 2631 | 2631.1 | 13 | 0,500 | 0,000 | 0,500 | 1,404 | 0,54 |
| statističar | 15-2041.00 | 2120 | 2120.6 | 19 | 0,789 | 0,254 | 0,789 | 1,383 | 0,74 |
| analitičar proračuna | 13-2031.00 | 2411 | 2411.1.4 | 13 | 0,500 | 0,204 | 0,520 | 1,503 | 0,77 |
| financijski analitičar | 13-2051.00 | 2412 | 2413.1 | 26 | 0,462 | 0,136 | 0,462 | 1,381 | 0,46 |
| financijski direktor | 11-3031.00 | 1211 | 1211.1 | 21 | 0,476 | 0,109 | 0,481 | 1,446 | 0,48 |
| računovođa | 13-2011.00 | 2411 | 2411.1 | 30 | 0,550 | 0,153 | 0,560 | 1,482 | 0,77 |
| direktor ljudskih potencijala | 11-3121.00 | 1212 | 1212.1 | 26 | 0,481 | 0,172 | 0,480 | 1,320 | 0,35 |
| specijalist za obuku i razvoj | 13-1151.00 | 2424 | 2424.2 | 20 | 0,550 | 0,154 | 0,553 | 1,198 | 0,25 |
| stručnjak za ljudske potencijale | 13-1071.00 | 2423 | 2423.3 | 26 | 0,635 | 0,267 | 0,644 | 1,360 | 0,27 |
| direktor marketinga | 11-2021.00 | 1221 | 1221.3.2 | 20 | 0,500 | 0,162 | 0,500 | 1,315 | 0,35 |
| stručnjak za marketing | 13-1161.00 | 2431 | 2431.10.3 | 13 | 0,500 | 0,000 | 0,500 | 1,427 | 0,54 |
| stručnjak za odnose s javnošću | 27-3031.00 | 2432 | 2432.9 | 18 | 0,583 | 0,257 | 0,591 | 1,285 | 0,33 |
| direktor općih i operativnih poslova | 11-1021.00 | 1120 | 1120.2 | 17 | 0,471 | 0,121 | 0,481 | 0,575 | 0,41 |

| Naziv zanimanja | O*NET-SOC | ISCO-08 | ESCO | n | GPT-4 β | SD | Izl. zanim. | AIOE (z) | Udio inf. |
|---|---|---|---|---|---|---|---|---|---|
| glavni izvršni direktor / vlasnik-upravitelj | 11-1011.00 | 1120 | 1120.3 | 31 | 0,452 | 0,269 | 0,460 | 1,334 | 0,32 |
| specijalist za poslovne operacije | 13-1199.04 | 2422 | 2421.2 | 21 | 0,571 | 0,179 | – | – | 0,52 |
| poslovni analitičar | 13-1111.00 | 2421 | 2421.1 | 11 | 0,409 | 0,302 | 0,405 | 1,432 | 0,55 |
| direktor prodaje | 11-2022.00 | 1221 | 1221.3.2.1 | 17 | 0,441 | 0,166 | 0,450 | 1,266 | 0,24 |
| komercijalist u prodaji (B2B) | 41-4012.00 | 3322 | 3322.1 | 19 | 0,605 | 0,209 | 0,621 | 0,822 | 0,16 |
| organizator sastanaka i događanja | 13-1121.00 | 3332 | 3332.2 | 21 | 0,476 | 0,249 | 0,486 | 0,374 | 0,29 |
| putnički agent | 41-3041.00 | 4221 | 4221.7 | 8 | 0,562 | 0,177 | 0,562 | 1,134 | 0,25 |
| upravitelj smještajnog objekta | 11-9081.00 | 1411 | 1411.1 | 24 | 0,458 | 0,204 | 0,457 | 0,402 | 0,17 |

*Napomena: Šifre ISCO-08 usklađene su sa službenim prijevodnikom SOC – ISCO-08 Ureda za statistiku rada SAD-a. Za specijalista za poslovne operacije izloženost na razini zanimanja i AIOE nisu dostupni, pa je to zanimanje isključeno iz testiranja hipoteza $H_{1a}$ i $H_2$ (efektivni n = 21). Udio informacijskih zadataka izračunan je iz klasifikacije zadataka opisane u odjeljku 3.1. n = broj zadataka u O*NET-u; GPT-4 β = mjera izloženosti na razini zadatka ; SD = standardna devijacija mjere GPT-4 β na razini zadatka; Izl. zanim. = izloženost na razini zanimanja (GPT-4 beta); AIOE (z) = standardizirani indeks izloženosti zanimanja umjetnoj inteligenciji (Felten, Raj i Seamans, 2021); Udio inf. = udio informacijsko-analitičkih zadataka u ukupnom broju zadataka zanimanja.*

Izvor: izračun autorica na temelju O*NET 29.0, Eloundou i sur. (2024), Felten, Raj i Seamans (2021), ESCO v1.2 i BLS OEWS (svibanj 2024.).

## 3.2. Rezultati empirijske analize

Deskriptivna analiza ukazuje na postojanje umjerenih razlika u prosječnoj izloženosti generativnoj umjetnoj inteligenciji između promatranih poslovnih područja (Tablica 2.). Zanimanja iz područja financija, ekonomske analize i poslovne analitike u prosjeku bilježe najviše vrijednosti AIOE mjere (iznad 1,4), dok zanimanja u poduzetništvu i turizmu bilježe najniže prosjeke (ispod 1,0). Raspon vrijednosti znatno je uži kod primjene GPT-4 beta mjere (od 0,405 do 0,596), što je izravna posljedica njezine matematičke konstrukcije; ta je mjera definirana kao udio unutar zatvorenog intervala [0, 1], dok AIOE mjera, kao standardizirani z-rezultat, nema takvo distribucijsko ograničenje.

**Tablica 2. Prosječna izloženost prema poslovnom području (SAD, prva razina)**

| Područje | n | GPT-4 beta (prosjek) | AIOE (prosjek) |
|---|---|---|---|
| Marketing i komunikacije | 3 | 0,530 | 1,342 |
| Prodaja | 2 | 0,536 | 1,044 |
| Financije | 4 | 0,506 | 1,453 |
| Poslovna analitika | 1 | 0,405 | 1,432 |
| Ekonomska analitika | 3 | 0,596 | 1,434 |
| Ljudski potencijali | 3 | 0,559 | 1,293 |
| Poduzetništvo | 3 | 0,471* | 0,954* |
| Turizam | 3 | 0,502 | 0,637 |

* Izračunano na dva zanimanja jer za specijalista za poslovne operacije mjere na razini zanimanja nisu dostupne.

Izvor: izrada autorica prema podacima Eloundou i sur. (2024) i Feltena, Raja i Seamansa (2021, 2023).

### *3.2.1. Struktura zaposlenosti prema izloženosti i trend zaposlenosti u Hrvatskoj*

Na drugoj razini analize izloženost je izračunana za osam dvoznamenkastih skupina ISCO-08 kao prosjek ponderiran američkom zaposlenošću, a potom agregirana ponderima ukupne zaposlenosti obiju zemalja za 2025. godinu (izvori: ILOSTAT i Eurostat). Ponderirani prosjek mjere GPT-4 beta iznosi 0,545 za SAD i 0,554 za Hrvatsku, dok za metriku AIOE iznosi 1,031 i 1,107. Blizina agregiranih prosjeka ne upućuje na strukturnu sličnost tržišta rada, već na udio zaposlenih u izloženijim skupinama.

Indeks različitosti raspodjela zaposlenosti iznosi 15,9 % za promatrani segment, odnosno 23,7 % za cjelokupno gospodarstvo. Hrvatska bilježi dvostruko veći udio zaposlenih u najmanje izloženoj skupini stručnjaka u pravnim, društvenim i kulturnim djelatnostima (19,3 % naspram 9,6 %), no to se odstupanje u prosjeku poništava. Proširenjem postupka na sve dvoznamenkaste skupine ISCO-08 prosjek mjere GPT-4 beta pada na 0,349

za Hrvatsku i 0,359 za SAD. Razina od 0,55 specifična je za analizirani poslovni segment i ne predstavlja nacionalni prosjek izloženosti.

Testiranje hipoteza $H_1$ do $H_5$ provedeno je isključivo na američkim podacima o zadacima i zanimanjima; hrvatski podaci o zaposlenosti koriste se samo za opis strukture i trenda.

**Tablica 3. Realizirana zaposlenost u RH prema ISCO-08, 2016. – 2025. (u tisućama)**

| Skupina ISCO-08 | 2016. | 2022. | 2025. | 2016. – 2022. | 2022. – 2025. | 2016. – 2025. |
|---|---|---|---|---|---|---|
| 24 Stručnjaci za poslovanje i upravljanje | 35,4 | 33,0 | 53,5 | −7 % | +62 % | +51 % |
| 12 Upravitelji za administrativne i komercijalne poslove | 14,2 | 14,4 | 23,8 | +1 % | +65 % | +68 % |
| 33 Poslovni i administrativni tehničari | 82,7 | 86,3 | 94,4 | +4 % | +9 % | +14 % |
| 21 Stručnjaci znanosti i inženjerstva | 33,5 | 53,2 | 55,5 | +59 % | +4 % | +66 % |
| 11 Glavni direktori i članovi uprava | 2,8 | 4,9 | 5,8 | +75 % | +18 % | +107 % |
| 26 Stručnjaci u pravnim, društvenim i kulturnim djelatnostima | 62,4 | 66,9 | 69,6 | +7 % | +4 % | +12 % |
| 14 Upravitelji u ugostiteljstvu i trgovini | 19,5 | 19,1 | 29,6 | −2 % | +55 % | +52 % |
| 42 Uredski djelatnici u odnosu s klijentima | 36,3 | 35,5 | 27,5 | −2 % | −23 % | −24 % |

*Napomena: u tisućama zaposlenih osoba, dobna skupina 15–74 godine. Eurostat za 2021. na svim hrvatskim serijama navodi prekid uzrokovan primjenom Uredbe (EU) 2019/1700 i novom metodologijom Ankete o radnoj snazi, pa vrijednosti prije i poslije te godine nisu u punoj mjeri usporedive.*

Izvor: Eurostat, tablica lfsa_egai2d (ažurirano 10. rujna 2026.).

Raspodjela zaposlenosti po skupinama ISCO-08 pokazuje da se rast ne odvija ujednačeno ni po skupinama ni tijekom vremena. Skupina stručnjaka za poslovanje i upravljanje, u koju se raspoređuje devet od 22 promatrana zanimanja, do 2022. bilježi pad od 7 %, a cjelokupan rast evidentan je nakon

te godine. Suprotan obrazac pokazuje skupina stručnjaka znanosti i inženjerstva, u kojoj gotovo sav rast nastaje prije 2022. Jedina skupina s padom tijekom cijelog razdoblja jest skupina uredskih djelatnika u odnosu s klijentima, i to izraženije u drugom podrazdoblju (−23 %). Razlika u vremenskom obrascu ne dopušta pripisivanje promjena pojavi generativne umjetne inteligencije: razdoblje nakon 2022. obuhvaća samo tri godine i u njemu se preklapaju tehnološki učinci, poslijepandemijski oporavak i promjene u ponudi radne snage.

### *3.2.2. Rezultati testiranja hipoteza (prva razina)*

Rezultati testiranja pet postavljenih hipoteza sažeti su u Tablici 4. Kruskal-Wallisov test proveden na prosjecima 21 zanimanja ne pokazuje statistički značajnu razliku između osam poslovnih područja ($H = 6{,}40$; $p = 0{,}494$). Za $H_{1a}$ odabran je neparametrijski test jer mali broj opažanja po skupini ($n = 21$ zanimanje raspoređeno u osam područja) i neujednačena veličina skupina ne omogućuju pouzdanu provjeru normalnosti raspodjele unutar skupina, koja je ključna pretpostavka parametrijskog testa. Na razini zadatka ($H_{1b}$) znatno veći uzorak ($n = 429$) i centralni granični teorem opravdavaju primjenu jednosmjerne analize varijance. Kada se identičan odnos testira na razini pojedinačnog zadatka, razlika između područja postaje statistički značajna ($F = 2{,}94$; $p = 0{,}005$; $\eta^2 = 0{,}047$). Mala veličina učinka ($\eta^2 = 0{,}047$) upućuje na to da poslovno područje objašnjava tek 4,7 % varijance izloženosti na razini zadatka, što je u skladu s pristupom utemeljenim na zadacima prema kojem je izloženost primarno svojstvo zadatka, a ne formalne klasifikacije zanimanja. Valja napomenuti da je statistička značajnost $H_{1b}$ utvrđena na razini pojedinačnih zadataka koji nisu neovisni unutar zanimanja (pseudoreplikacija), što narušava pretpostavku neovisnosti opažanja u jednosmjernoj analizi varijance i umanjuje pouzdanost zaključka o međugrupnoj razlici.

**Tablica 4. Rezultati testiranja hipoteza**

| H | Mjera | Test | Rezultat | Veličina učinka | Zaključak |
|---|---|---|---|---|---|
| H1a | GPT-4 beta (razina zanimanja) | Kruskal-Wallis (prosjeci zanimanja) | H = 6,40; p = 0,494 (n = 21) | – | Nije podržana |
| H1b | GPT-4 beta (razina zadatka) | Jednosmjerna ANOVA (sirovi zadaci) | F = 2,94; p = 0,005 | $\eta^2$ = 0,047 | Podržana |
| H2 | GPT-4 beta (razina zanimanja) | Regresija: izloženost ~ udio inf. zadataka | $R^2$ = 0,036; p = 0,410 (n = 21) | $R^2$ = 0,036 | Nije podržana |
| H3 | GPT-4 beta (razina zadatka) | Dekompozicija varijance (zadatak ugniježđen u zanimanju) | $\eta^2$ = 0,155; ICC(1) = 0,12; unutar skupni udio 84,5 % | $\eta^2$ = 0,155; ICC(1) = 0,12 | Podržana |
| H4 | GPT-4 beta (razina zadatka) | Mann-Whitney U | U = 6.275,5; p < 0,001 | r = 0,22 | Podržana |
| H5 | GPT-4 beta (razina zadatka, prosjek i SD po zanimanju) | Pearsonova korelacija prosjek–SD | r = 0,216; p = 0,335 | r = 0,216 | Nije podržana |

Izvor: izrada autorica.

Udio informacijsko-analitičkih zadataka ne objašnjava razlike u izloženosti između zanimanja (b = 0,084; SE = 0,100; t = 0,843; p = 0,410; $R^2$ = 0,036; n = 21). Budući da je isti kontrast na razini pojedinačnih zadataka značajan ($H_4$), rezultat upućuje na to da se učinak gubi pri agregaciji na razinu zanimanja. Izostanak značajnosti kod $H_2$ ne proturječi potvrdi $H_4$, već proizlazi iz redukcije varijance pri agregaciji na razinu zanimanja. Dok udio klasificiranih zadataka kao mjera kompozicije ne objašnjava varijancu među zanimanjima ($\eta^2$ = 0,155) zbog malog uzorka ($H_2$), izravna usporedba mikropodataka ($H_4$) upućuje na to da su informacijski zadaci intrinzično izloženiji od interpersonalnih. Ta se sustavna razlika odnosi isključivo na razinu zadatka i ne smije se ekstrapolirati na zanimanje kao cjelinu.

Dekompozicija varijance pokazuje da 84,5 % ukupne varijance izloženosti nastaje između zadataka unutar istoga zanimanja, a 15,5 % između zanimanja ($\eta^2$ = 0,155; F(21,407) = 3,56; p < 0,001). Procijenjeni koeficijent unutarrazredne korelacije iznosi ICC(1) = 0,12. Razlika između $\eta^2$ = 0,155 i

ICC(1) = 0,12 proizlazi iz naravi dvaju pokazatelja: $\eta^2$ je opisni udio međugrupnoga zbroja kvadrata u uzorku i precjenjuje populacijski udio jer razlike među prosjecima zanimanja sadržavaju i slučajnu varijaciju zadataka, dok ICC(1) tu komponentu oduzima uzimajući u obzir neujednačen broj zadataka po zanimanju, pa daje konzervativniju procjenu.

Nalaz o varijabilnosti unutar zanimanja deskriptivne je naravi i predstavlja gornju granicu stvarne heterogenosti sadržaja zbog uključene mjerne pogreške i ugniježđene strukture podataka u kojoj zadaci unutar istoga zanimanja nisu neovisne opservacije. Informacijsko-analitički zadaci (n = 173) bilježe višu prosječnu izloženost (0,578) od interpersonalnih (n = 61; 0,475) uz medijan od 0,500 u objema kategorijama, a razlika je statistički značajna (Mann-Whitneyjev U = 6.275,5; $p < 0,001$). Rezultat implicira da je inherentna priroda zadatka mjerena intenzitetom socijalnoga konteksta i afektivne regulacije, relevantnija determinanta izloženosti od formalne klasifikacije zanimanja.

Konačno, na uzorku od 22 zanimanja nije utvrđena statistički značajna povezanost prosječne izloženosti i varijabilnosti unutar skupine ($r = 0,216$; $p = 0,335$). Interval pouzdanosti obuhvaća i nulu i vrijednosti suprotnoga predznaka, pa se odsutnost učinka ne može razlikovati od učinka male veličine. Rezultat se ne tumači kao potpora hipotezi.

## 3.3. Interpretacija rezultata

Rezultati istraživanja u cjelini ne pružaju empirijsku osnovu za jednoznačno prihvaćanje svih postavljenih hipoteza, no nude metodološki konzistentan i teorijski utemeljen uvid u mehanizme izloženosti poslovnih i ekonomskih zanimanja generativnoj umjetnoj inteligenciji. Hipoteza $H_3$ podržana je deskriptivnom dekompozicijom varijance, dok $H_4$ pokazuje statistički značajnu razliku. Hipoteza $H_1$ podržana je primjenom dezagregirane jedinice analize, dok za hipoteze $H_2$ i $H_5$ na promatranom uzorku nije utvrđena statistički značajna povezanost. Izostanak statističke značajnosti kod potonjih ne opravdava zaključak o nepostojanju učinka, ali se ne može ni pripisati isključivo ograničenjima uzorka jer ista vrijede i za značajne rezultate.

Ključni analitički doprinos istraživanja proizlazi iz konvergencije ishoda testiranja hipoteza $H_3$ i $H_4$. Pripadnost određenomu zanimanju objašnjava tek manji dio ukupne varijance izloženosti generativnoj umjetnoj inteligenciji ($\eta^2 = 0,155$), dok dominantni dio varijabilnosti determinira heterogenost

zadataka unutar pojedinih zanimanja. Pritom je razina izloženosti sustavno niža kod radnih zadataka koji zahtijevaju visok intenzitet interpersonalne interakcije i kontekstualne prosudbe, a značajno viša kod zadataka usmjerenih na obradu i sintezu informacija. Takva dekompozicija varijance u skladu je s teorijom prema kojoj generativna umjetna inteligencija ne implicira supstituciju zanimanja u cjelini, nego potiče asimetričnu redistribuciju i augmentaciju na razini elementarnih radnih procesa. Nalaz je time komplementaran modelima ekonomike rada utemeljenima na zadacima (engl. *task-based approach*).

Odstupanje rezultata testiranja pothipoteze $H_{1a}$ na razini zanimanja u odnosu na pothipotezu $H_{1b}$ na razini zadatka predvidljiva je ekonometrijska posljedica niske statističke snage i redukcije varijance među skupinama. Ograničen broj opažanja unutar pojedinih poslovnih područja, u kombinaciji s visokom varijabilnošću unutar samih područja, smanjuje vjerojatnost odbacivanja nulte hipoteze pri agregiranim usporedbama. Proširenje obujma uzorka u budućim istraživanjima povećalo bi statističku snagu testa, no i postojeći nalazi na razini mikropodataka upućuju na postojanje razlika u prosječnoj izloženosti između promatranih poslovnih područja, uz napomenu da je ta razlika utvrđena na razini zadatka i da na agregiranoj razini zanimanja nije statistički potvrđena. Dodatno, mala veličina učinka ($\eta^2 = 0{,}047$) i ovisnost opažanja (zadaci istoga zanimanja dijele karakteristike) ograničavaju snagu nalaza na razini zadatka.

Valjanost i doseg uopćavanja ovih zaključaka omeđuje pet metodoloških ograničenja. Prvo, klasifikacija zadataka na informacijsko-analitičke i interpersonalne izvedena je metodom pretraživanja ključnih riječi unutar tekstualnih opisa. Slijedom toga, ishod testiranja hipoteze $H_4$ predstavlja preliminaran empirijski signal, dok se izostanak potvrde hipoteze $H_2$ ne može smatrati konkluzivnim dokazom o nepostojanju teorijske veze.

Drugo, primarni su indikatori izloženosti konstruirani na temelju američke taksonomije O*NET i prenose se na hrvatski kontekst bez provjere. Provedena usporedba ponderiranih prosjeka tu pretpostavku ne provjerava jer se u oba izračuna koriste iste američke vrijednosti izloženosti po skupinama, a mijenja se samo struktura zaposlenosti. Usporedba je dodatno ograničena visokom agregacijom hrvatskih podataka koja prikriva razlike u sadržaju zadataka, osobito u intenzitetu digitalizacije radnih procesa i u internoj podjeli rada. Provjera prenosivosti zahtijevala bi hrvatske podatke o sadržaju zadataka. Nalazi testiranja hipoteza stoga ostaju vezani uz američko tržište rada.

Treće, broj zadataka po zanimanju nije ujednačen i kreće se od 8 do 31, pa procjene varijabilnosti unutar skupine nemaju jednaku preciznost. Zanimanja s malim brojem zadataka tako daju manje pouzdane procjene standardne devijacije. Četvrto, struktura podataka u kojoj zanimanja obuhvaćaju između 8 i 31 zadatka implicira ugniježđenost. Budući da zadaci unutar istoga zanimanja dijele organizacijski kontekst, njihove metrike izloženosti nisu potpuno nezavisne opservacije. Rezultat testiranja hipoteze $H_3$ to potvrđuje: procijenjeni ICC(1) iznosi 0,12, što upućuje na to da je u takvoj strukturi broj efektivno neovisnih opažanja znatno manji od ukupnoga broja zadataka, pa su p-vrijednosti testova $H_{1b}$ i $H_4$ vjerojatno podcijenjene, a statistička značajnost precijenjena. Smjer i veličina učinka ipak ostaju informativni, no pouzdanost i mogućnost generalizacije rezultata na širu populaciju poslovnih zanimanja time su ograničeni. Budući da mali uzorak zanimanja ($n = 22$) s neujednačenim brojem zadataka (8–31) ne jamči reprezentativnost cjelokupnoga sektora, nalaze valja interpretirati kao indikativne za promatrani skup zanimanja, a ne kao zaključke primjenjive na sva poslovna i ekonomska zanimanja.

Peto, rad primjenjuje inačicu mjere GPT-4 beta utemeljenu na modelskim oznakama umjesto na procjenama ljudskih anotatora. Premda su agregatni prosjeci bliski (0,545 naspram 0,539), sustavne razlike u rangiranju zanimanja nisu testirane, pa utjecaj odabira modelske inačice na stabilnost rezultata ostaje otvoren.

Zaključno, strukturni uvid dobiven testiranjem hipoteza $H_3$ i $H_4$ upućuje na potrebu ponovne konceptualizacije visokoškolskih kurikuluma u području ekonomije i poslovne administracije. Umjesto linearne i reaktivne modifikacije studijskih programa prema nominalnim kategorijama zanimanja koja se u javnome diskursu označavaju kao ugrožena, rezultati sugeriraju da bi ishode učenja trebalo restrukturirati prema specifičnim tipovima vještina. Fokus obrazovnih procesa potrebno je pomaknuti prema razvoju naprednih ljudskih kompetencija u domenama interpersonalne koordinacije, pregovaranja i nestrukturirane kontekstualne prosudbe. Te je komparativne prednosti ljudskoga rada nužno razvijati u sinergiji s vještinama AI-potpomognute obrade i sinteze informacija, čime se radna snaga priprema za radna mjesta čiji će se stvarni sadržaj zadataka kontinuirano transformirati neovisno o njihovoj formalnoj klasifikaciji.

# 4. ZAKLJUČNA RAZMATRANJA

Rezultati ovoga rada upućuju na to da je tehnološka izloženost primarno inherentno svojstvo radnoga zadatka, a ne samoga zanimanja kao monolitne kategorije. Rezultati dekompozicije varijance pokazuju da pripadnost specifičnom zanimanju objašnjava svega 15,5 % ukupne varijabilnosti, dok preostalih 84,5 % otpada na razlike unutar skupine među zadacima. Informacijsko-analitički zadaci pritom generiraju sustavno višu razinu izloženosti u odnosu na interpersonalne i prosudbene. Sukladno tome, divergencija među poslovnim domenama iščezava na agregiranoj razini zanimanja, a postaje značajna isključivo na dezagregiranoj razini pojedinačnih zadataka. Navedeni nalazi u skladu su s teorijskim pristupom utemeljenim na zadacima, upućujući na to da generativna umjetna inteligencija ne eliminira zanimanja u cijelosti, nego iznutra transformira i redefinira njihov strukturni sadržaj (Autor i sur., 2003; Acemoglu i Restrepo, 2019).

Komparativna analiza indicira prividno identične agregatne prosjeke izloženosti za Republiku Hrvatsku i Sjedinjene Američke Države, no ta je bliskost posljedica neosjetljivosti ponderiranoga prosjeka na kompoziciju zaposlenosti, a ne dokaz strukturne sličnosti tržišta rada. Longitudinalna analiza trenda domaće zaposlenosti od 2016. do 2025. godine u visoko izloženim skupinama otkriva izrazitu heterogenost, pri čemu kontinuirani pad bilježe isključivo uredski djelatnici u odnosu s klijentima, uz napomenu da se stvarni učinci tehnologije uvedene krajem 2022. godine u ovim serijama tek počinju odražavati.

Praktične implikacije rada odnose se na tri skupine dionika. Visokoškolskim institucijama nalazi sugeriraju da reviziju kurikuluma ne treba voditi reaktivnim popisima zanimanja visoko izloženih automatizaciji, nego da ishode učenja valja usmjeriti na razvoj vještina interpersonalne koordinacije, pregovaranja i nestrukturirane prosudbe u sinergiji s naprednim tehnološkim kompetencijama. Za poslodavce to implicira nužnost preoblikovanja radnih mjesta umjesto ukidanja pozicija, dok za nositelje javnih politika proizlazi potreba za uvođenjem granulirane službene statistike zaposlenosti i njezinim praćenjem tijekom vremena. Konačno, premošćivanje opisanih metodoloških ograničenja definira smjer budućih istraživanja, koja bi trebala zamijeniti klasifikaciju ključnim riječima metodom dvostrukoga neovisnog kodiranja ili provjerene strojne semantičke analize, proširiti uzorak zanimanja radi veće statističke snage testova te primijeniti panel modele za kauzalnu procjenu dugoročnih učinaka.

## LITERATURA

Acemoglu, D. (2025). The simple macroeconomics of AI. *Economic Policy*, 40(121), 13–58. https://doi.org/10.1093/epolic/eiae042

Acemoglu, D. i Autor, D. (2011). Skills, tasks and technologies: Implications for employment and earnings. U O. Ashenfelter i D. Card (ur.), *Handbook of Labor Economics* (Vol. 4B, str. 1043–1171). Amsterdam: Elsevier. https://doi.org/10.1016/S0169-7218(11)02410-5

Acemoglu, D. i Restrepo, P. (2019). Automation and new tasks: How technology displaces and reinstates labor. *Journal of Economic Perspectives*, 33(2), 3–30. https://doi.org/10.1257/jep.33.2.3

Arntz, M., Gregory, T. i Zierahn, U. (2016). *The risk of automation for jobs in OECD countries: A comparative analysis* (OECD Social, Employment and Migration Working Papers No. 189). Paris: OECD Publishing. https://doi.org/10.1787/5jlz9h56dvq7-en

Autor, D. H. (2015). Why are there still so many jobs? The history and future of workplace automation. *Journal of Economic Perspectives*, 29(3), 3–30. https://doi.org/10.1257/jep.29.3.3

Autor, D. H., Levy, F. i Murnane, R. J. (2003). The skill content of recent technological change: An empirical exploration. *The Quarterly Journal of Economics*, 118(4), 1279–1333. https://doi.org/10.1162/003355303322552801

Bick, A., Blandin, A. i Deming, D. J. (2024). *The rapid adoption of generative AI* (NBER Working Paper No. 32966). Cambridge, MA: National Bureau of Economic Research. https://doi.org/10.3386/w32966

Brynjolfsson, E., Li, D. i Raymond, L. (2025). Generative AI at work. *The Quarterly Journal of Economics*, 140(2), 889–942. https://doi.org/10.1093/qje/qjae044

Brynjolfsson, E., Mitchell, T. i Rock, D. (2018). What can machines learn, and what does it mean for occupations and the economy? *AEA Papers and Proceedings*, 108, 43–47. https://doi.org/10.1257/pandp.20181019

Cazzaniga, M., Jaumotte, F., Li, L., Melina, G., Panton, A. J., Pizzinelli, C., Rockall, E. i Tavares, M. M. (2024). *Gen-AI: Artificial intelligence and the future of work* (IMF Staff Discussion Note SDN2024/001). Washington, DC: International Monetary Fund. https://doi.org/10.5089/9798400262548.006

Dell'Acqua, F., McFowland, E., Mollick, E. R., Lifshitz-Assaf, H., Kellogg, K., Rajendran, S., Krayer, L., Candelon, F. i Lakhani, K. R. (2023). *Navigating the jagged technological frontier: Field experimental evidence of the effects of AI on knowledge worker productivity and quality* (Harvard Business School Working Paper No. 24-013). https://doi.org/10.2139/ssrn.4573321

Eloundou, T., Manning, S., Mishkin, P. i Rock, D. (2024). GPTs are GPTs: Labor market impact potential of LLMs. *Science*, 384(6702), 1306–1308. https://doi.org/10.1126/science.adj0998

Felten, E., Raj, M. i Seamans, R. (2021). Occupational, industry, and geographic exposure to artificial intelligence: A novel dataset and its potential uses. *Strategic Management Journal*, 42(12), 2195–2217. https://doi.org/10.1002/smj.3286

Felten, E., Raj, M. i Seamans, R. (2023). *How will language modelers like ChatGPT affect occupations and industries?* arXiv. https://doi.org/10.48550/arXiv.2303.01157

Frey, C. B. i Osborne, M. A. (2017). The future of employment: How susceptible are jobs to computerisation? *Technological Forecasting and Social Change*, 114, 254–280. https://doi.org/10.1016/j.techfore.2016.08.019

Gmyrek, P., Berg, J. i Bescond, D. (2023). *Generative AI and jobs: A global analysis of potential effects on job quantity and quality* (ILO Working Paper No. 96). Geneva: International Labour Organization. https://doi.org/10.54394/FHEM8239

Hui, X., Reshef, O. i Zhou, L. (2024). The short-term effects of generative artificial intelligence on employment: Evidence from an online labor market. *Organization Science*, 35(6), 1977–1989. https://doi.org/10.1287/orsc.2023.18441

Humlum, A. i Vestergaard, E. (2025). *Still waters, rapid currents: Early labor market transformation under generative AI* (NBER Working Paper No. 33777). Cambridge, MA: National Bureau of Economic Research. https://doi.org/10.3386/w33777

Noy, S. i Zhang, W. (2023). Experimental evidence on the productivity effects of generative artificial intelligence. *Science*, 381(6654), 187–192. https://doi.org/10.1126/science.adh2586

Europska komisija (2022). ESCO klasifikacija, verzija 1.2. https://esco.ec.europa.eu/ (pristupljeno 15. rujna 2026.).

ILOSTAT (2026). Employment by sex and occupation (thousands) – annual, indikator EMP_TEMP_SEX_OC2_NB_A. Međunarodna organizacija rada. https://ilostat.ilo.org/ (pristupljeno 15. rujna 2026.).

U. S. Bureau of Labor Statistics (2024). Occupational Employment and Wage Statistics, May 2024. https://www.bls.gov/oes/ (pristupljeno 15. rujna 2026.).

U. S. Bureau of Labor Statistics. 2010 SOC to ISCO-08 crosswalk. https://www.bls.gov/soc/ (pristupljeno 15. rujna 2026.).

# EXPOSURE OF BUSINESS AND ECONOMICS OCCUPATIONS TO GENERATIVE ARTIFICIAL INTELLIGENCE: A TASK-LEVEL ANALYSIS WITH REFERENCE TO THE CROATIAN LABOUR MARKET

***Abstract***

*Conventional estimates of labour-market exposure to generative artificial intelligence are generally reported at the level of whole occupations. This paper re-examines that approach and investigates whether the exposure of business and economics occupations is a homogeneous property of the occupations themselves or a heterogeneous characteristic of their work tasks. The empirical analysis covers 22 occupations in eight business domains (429 tasks), unambiguously mapped across the O*NET-SOC, ISCO-08 and ESCO classifications. GPT-4 beta is the primary exposure measure, while AIOE (Artificial Intelligence Occupational Exposure) serves as a supplementary descriptive measure. Five hypotheses are tested with the Kruskal-Wallis test, one-way analysis of variance, variance decomposition ($\eta^2$, ICC(1)), linear regression, the Mann-Whitney U test and Pearson correlation. Variance decomposition shows that occupation membership explains only 15,5 % of the total variance in exposure, while the remaining 84,5 % is attributable to differences among tasks within the same occupation. Information-analytical tasks are significantly more exposed than interpersonal tasks. Differences among business domains are statistically significant at the task level but not at the occupation level. A comparison of the employment structures of Croatia and the United States yields nearly identical weighted averages of exposure, reflecting the insensitivity of the average to employment composition rather than structural similarity. Employment in highly exposed groups in Croatia developed unevenly across groups and over time between 2016 and 2025. The findings suggest that higher education should align learning outcomes with task types rather than with lists of endangered occupations. Limitations stem from keyword-based task classification, the small occupational sample and the aggregation of Croatian data. The paper contributes a variance decomposition showing that exposure is primarily a characteristic of the individual task rather than of the occupation as a whole, and in describing the Croatian employment structure at the ISCO-08 two-digit level.*

***Keywords:*** *generative artificial intelligence, occupational exposure, work tasks, labour market, higher education.*

JEL klasifikacija: L26, J16, L53

Prethodno priopćenje

# STRUKTURNE ZNAČAJKE, PREPREKE I RAZVOJNE PERSPEKTIVE ŽENA PODUZETNICA U HRVATSKOJ: REZULTATI EMPIRIJSKOG ISTRAŽIVANJA

Ivana Kovač*

Patricija Adanić**

## SAŽETAK

Rad ispituje strukturne značajke, prepreke i razvojne perspektive žena poduzetnica u Hrvatskoj. Cilj je utvrditi demografski i poslovni profil vlasnica mikro, malih i srednjih poduzeća, prepoznati motive za ulazak u poduzetništvo, rangirati prepreke s kojima se susreću te procijeniti u kojoj se mjeri postojeća institucionalna podrška doživljava dostatnom. Istraživanje se temelji na kvantitativnoj anketi provedenoj tijekom jednomjesečnog razdoblja u ljeto 2025. godine. Strukturirani upitnik od dvadeset i pet pitanja, raspoređenih u šest tematskih cjelina, distribuiran je putem mreža žena poduzetnica i kontaktne baze Hrvatske agencije za malo gospodarstvo, inovacije i investicije (HAMAG-BICRO). Od 220 odgovora, u analizu je uključen 191 valjan odgovor aktivnih poduzetnica, obrađen deskriptivnom i

* Izv. prof. dr. sc. Ivana Kovač, Sveučilište u Zagrebu, Ekonomski fakultet (e-mail: ikovac4@net.efzg.hr), korespondirajući autor.

** Patricija Adanić, MBA, Hrvatska agencija za malo gospodarstvo, inovacije i investicije (HAMAG-BICRO) (e-mail: patricija.adanic@gmail.com).

usporednom statistikom. Žensko poduzetništvo u Hrvatskoj pretežno je projekt profesionalne zrelosti: koncentrirano je među visokoobrazovanim ženama u četrdesetim i pedesetim godinama koje vode mikropoduzeća u uslužnim djelatnostima urbanih sredina. Motivacijskom strukturom dominiraju prilika i želja za samostalnošću, a ne nužda. Najčešće prijavljena prepreka nije pristup kapitalu, već administrativno-birokratsko opterećenje, a slijedi usklađivanje poslovnih i obiteljskih obveza. Institucionalna podrška široko se koristi, ali se ocjenjuje tek umjereno. Od triju hipoteza, ona koja financiranje označava glavnom preprekom je opovrgnuta, dok su hipoteze o primatu motiva samostalnosti i o percipiranoj nedostatnosti institucionalne podrške potvrđene. Uzorak je neprobabilistički pa nalazi opisuju odnose unutar uzorka, a ne uzročne učinke i populacijske parametre; podaci se temelje na samoprocjeni. Rad donosi recentne, sektorski i regionalno sveobuhvatne anketne dokaze o hrvatskim poduzetnicama i preuređuje uobičajenu hijerarhiju prepreka, s izravnim implikacijama za oblikovanje politike podrške.

**Ključne riječi:** žensko poduzetništvo, mikropoduzeća, poduzetnička motivacija, prepreke poduzetništvu, institucionalna podrška, Hrvatska.

# 1. UVOD

Poduzetništvo je među ključnim pokretačima gospodarskog rasta, zapošljavanja i inovacija, a njegova je važnost osobito izražena u tranzicijskim gospodarstvima u kojima je razvoj malih i srednjih poduzeća (MSP-ova) pridonio diversifikaciji tržišta i jačanju konkurentnosti. U okviru toga šireg procesa žensko se poduzetništvo iz rubnog područja istraživanja postupno pomaknulo prema središtu razvojnih politika. Međutim, taj napredak nije ujednačen. Premda žene predstavljaju značajan neiskorišteni potencijal poduzetničkih sposobnosti, i dalje su nedovoljno zastupljene među vlasnicima poduzeća i u upravljačkim strukturama, kako u razvijenim zemljama tako i u zemljama u razvoju. Međunarodni pokazatelji Global Entrepreneurship Monitora (GEM), Organizacije za ekonomsku suradnju i razvoj (OECD) te Svjetske banke upućuju na prepoznatljiv obrazac: žene rjeđe od muškaraca ulaze u poduzetništvo, češće posluju u tradicionalnim djelatnostima i sektorima s nižim profitnim maržama te imaju ograničen pristup kapitalu, mentorstvu i poslovnim mrežama. U Hrvatskoj žene čine približno trećinu poduzetnika, pri čemu se njihov udio povećava polagano, ali kontinuirano. Uz gospodarska ograničenja, žene se suočavaju i sa

sociokulturnim preprekama među kojima se osobito ističu rodni stereotipi i teškoće usklađivanja poslovnih i privatnih obveza. U takvim okolnostima žensko poduzetništvo nije samo gospodarsko pitanje. Ono je povezano s rodnom ravnopravnošću, ekonomskom neovisnošću žena, demografskim kretanjima i ukupnom kvalitetom života. Povećanje broja žena koje ulaze u poslovni svijet stoga ne jača samo gospodarstvo nego pridonosi i društvenoj koheziji te otpornosti lokalnih zajednica.

Istraživački problem ovoga rada odnosi se na postojani raskorak između prepoznatog potencijala ženskog poduzetništva i strukturnih uvjeta koji ograničavaju njegov rast. Cilj je rada produbiti razumijevanje načina i razloga zbog kojih žene u Hrvatskoj ulaze u poduzetništvo te utvrditi čimbenike koji oblikuju njihov poduzetnički put. Iz toga cilja proizlaze četiri istraživačka pitanja. Prvo, kakav je demografski i poslovni profil poduzetnica u Hrvatskoj? Drugo, koji su njihovi motivi za pokretanje poslovnog pothvata te prevladavaju li pritom motivi prilike ili nužnosti? Treće, koje prepreke smatraju najizraženijima? Četvrto, u kojoj se mjeri koriste dostupnim oblicima institucionalne potpore i kako ih ocjenjuju? Doprinos rada je prije svega u empirijskim nalazima koji omogućuju prepoznavanje zajedničkih obrazaca i utvrđivanje sektorskih posebnosti glede žena poduzetnica te preporukama vezanim uz javne politike.

## 2. FENOMEN ŽENSKOG PODUZETNIŠTVA

Pojam ženskog poduzetništva ušao je u znanstveni diskurs 1976. godine kada ga je Schwartz (1976) opisala kao posebnost obilježenu strukturnim ograničenjima te motiviranu potrebom za neovisnošću i usklađivanjem poslovnog i obiteljskog života žena. Hisrich i O'Brien (1981) definirali su poduzetnicu kao osobu koja pokreće i upravlja poslovnim pothvatom, preuzima rizik njegova poslovanja te zadržava znatan stupanj kontrole nad poslovnim odlukama. Goffee i Scase (1985) promatrali su žensko poduzetništvo kao društvenu praksu oblikovanu rodnim normama i vrijednosnim kompromisima, u okviru koje žene ne teže isključivo dobiti, nego i autonomiji, fleksibilnosti te osjećaju smisla. Istaknuli su da poduzetnice češće razvijaju manje hijerarhijske i više participativne stilove vođenja i upravljanja. Dva su segmenta dodatno učvrstila ovo područje istraživanja. OECD je potkraj 1980-ih godina poduzetnice počeo promatrati kao posebnu ciljnu skupinu unutar politika usmjerenih na mala i srednja poduzeća, a u izvješću iz 1998. godine iznio je široko prihvaćenu

funkcionalnu definiciju prema kojoj je poduzetnica osoba koja pokreće, organizira i vodi poslovanje. U izvješću iz 2004. godine žensko je poduzetništvo potom smješteno u okvir brojnih prepreka, ali i prilika te institucionalne potpore (OECD, 2004).

Empirijsku potvrdu tih ranih nalaza pruža Global Entrepreneurship Monitor (GEM), konzorcij akademskih istraživača koji od 1999. godine sustavno prati poduzetničku aktivnost u pedesetak zemalja svijeta. Prema izvješću GEM Women's Entrepreneurship Report stopa uključenosti žena u ranu fazu poduzetničke aktivnosti porasla je s prosječnih 6,1 % u razdoblju 2001. – 2005. na 10,4 % u razdoblju 2021. – 2023., što upućuje na postupno, no još uvijek nedovršeno zatvaranje rodnog jaza u poduzetništvu (GEM, 2024). Istodobno, novije je istraživanje utvrdilo da žene za 47 % češće od muškaraca obustavljaju poslovanje iz obiteljskih ili osobnih razloga, čime se potvrđuje trajna napetost između poduzetničke aktivnosti i skrbničkih obveza (GEM, 2025). Kvantitativan rast sudjelovanja žena u poduzetništvu sam po sebi, dakle, ne jamči i kvalitativno izjednačavanje uvjeta poslovanja.

Žensko poduzetništvo nije moguće primjereno razumjeti primjenom naizgled rodno neutralnih modela koji muško iskustvo uzimaju kao standard (Bruin, Brush i Welter, 2007). Postojeći okvir 3M, koji obuhvaća tržišta, novac i menadžment, proširen je dvama dodatnim elementima: majčinstvom te makro- i mezookruženjem. Time su poduzetničke odluke smjestili u širi institucionalni i sociokulturni kontekst, umjesto da ih svode isključivo na individualne osobine.

Prepreke ženama u bavljenju poduzetničkom aktivnošću brojne su. Postoje brojna ograničenja u financiranju, ljudskom kapitalu, sociokulturnom i institucionalnom okruženju (Cardella i sur., 2020). Brush, Bruin i Welter (2009) ta ograničenja smještaju u šire makrookruženje i mezookruženje, umjesto da ih tumače individualnim nedostacima poduzetnica. Financijske prepreke očituju se u otežanom pristupu kreditima i vlasničkom kapitalu te manjoj raspoloživosti osobnih financijskih sredstava. Prepreke povezane s ljudskim kapitalom uključuju ograničena menadžerska znanja i manjak mentorske potpore. Sociokulturne prepreke odnose se na rodne stereotipe i obiteljska očekivanja, dok se institucionalne prepreke pojavljuju u obliku zakonskih okvira i instrumenata potpore koji nisu dovoljno prilagođeni poduzećima u vlasništvu žena, što posebno ističe i analiza Svjetske banke o neravnopravnosti žena (World Bank, 2024).

Dubinsku analizu financijskih prepreka pružaju istraživanja usmjerena izravno na rodni jaz u pristupu vlasničkom kapitalu. Na uzorku američkih novoosnovanih poduzeća utvrđeno je da poduzetnice, uz usporedive razine ljudskoga kapitala i kvalitete poslovnog pothvata, sustavno ostvaruju manju vjerojatnost pribavljanja vanjskog financiranja, pri čemu razliku dijelom objašnjavaju investitorska uvjerenja o riziku, a dijelom razlike u signalizacijskim strategijama poduzetnica i poduzetnika (Guzman i Kacperczyk, 2019). Coleman i Robb (2012) slične nalaze dobivaju analizirajući strukturu kapitala novoosnovanih poduzeća u vlasništvu žena u Sjedinjenim Američkim Državama, pokazujući da se poduzetnice u prosjeku oslanjaju na manja vlastita i obiteljska sredstva, umjesto na institucionalne izvore financiranja. Sustavan pregled empirijske literature koji obuhvaća sedamdesetak studija objavljenih između 2001. i 2024. godine potvrđuje da muškarci ostvaruju prednost u pribavljanju rizičnog kapitala i sredstava poslovnih anđela, dok se poduzetnice uspješnije snalaze u modelima skupnog financiranja, što upućuje na strukturnu, a ne isključivo bihevioralnu prirodu jaza u financiranju (Koziol, Schmitz i Bort, 2025).

Poseban je istraživački doprinos vezan uz ulogu društvenog kapitala i poslovnih mreža u poduzetničkom pothvatu žena. Veća zastupljenost srodnika unutar poduzetničke mreže smanjuje vjerojatnost pokretanja posla te pokazuje da žene, u usporedbi s muškarcima, češće grade mreže sastavljene pretežno od obiteljskih i rodbinskih veza, čime raspolažu manje raznolikim, a time i manje produktivnim izvorima informacija i resursa (Renzulli, Aldrich i Moody, 2000). Slično, poduzetnice u odnosu na poduzetnike u većoj mjeri koriste jake, a manje slabe veze pri pribavljanju poslovne pomoći, što ih ograničava u dosegu do novih tržišnih i financijskih informacija (Aldrich, Elam i Reese, 1996). Navedeni nalazi upotpunjuju ranije spomenuti okvir 3M, pokazujući da mrežni mehanizmi na mezorazini djeluju kao dodatni posrednik između institucionalnog okruženja i pojedinačne poduzetničke odluke. Na primjer, Zirdum i Cvitanović (2017) ukazuju na otežan pristup financiranju, izostanak sustavne i kontinuirane institucionalne potpore, ograničenu uključenost u poslovne mreže te sklonost koncentraciji žena u djelatnostima s nižom dodanom vrijednošću u Hrvatskoj. Zagovaraju trajnu i rodno osjetljivu potporu, umjesto povremenih i generički oblikovanih mjera.

Jedno od središnjih pitanja u literaturi odnosi se na to ulaze li žene u poduzetništvo prije svega zbog uočene prilike ili zbog nužde te na koji način vrijednosna orijentacija posreduje u toj odluci. Nalazi upućuju na to da se rodne razlike manje odnose na poduzetnički kapacitet, a više na motivacijski

profil. Istraživanjem osobina ličnosti i poduzetničkih namjera utvrđeno je da žene koje namjeravaju postati poduzetnice postižu više rezultate na dimenziji zajedništva koja obuhvaća otvorenost i suradničku orijentaciju. S druge strane, osobine poput samopoštovanja, usmjerenosti na moć i sklonosti riziku snažnije su povezane s poduzetničkom namjerom muškaraca. Ta razlika ne upućuje na manju ambicioznost žena, nego na drukčije razumijevanje uspjeha u kojem se gospodarski i društveni ishodi promatraju povezano. Takvo poimanje uspjeha može utjecati na izbor djelatnosti, stil vođenja i strategiju rasta poduzeća (Zisser i sur., 2019).

Zanimljivo je da se poduzetnicama, na temelju rezultata istraživanja pristranosti u evaluaciji poduzetničkih pothvata, češće postavljaju pitanja usmjerena na prevenciju i rizike, dok se poduzetnicima češće postavljaju pitanja usmjerena na rast i razvoj (Kanze i sur., 2018). Taj mehanizam djelomično objašnjava nejednak pristup kapitalu, čak i pri usporedivim razinama poslovne uspješnosti. S ovim je nalazima usko povezana i perspektiva obiteljske ugrađenosti (family embeddedness), koju su razvili Aldrich i Cliff (2003). Prema toj perspektivi, poduzetnička se odluka žena ne može primjereno razumjeti izvan konteksta obiteljske strukture, raspoloživih resursa i normi koje oblikuju vrijeme, kapital i legitimitet potreban za poduzetnički pothvat. Time se ponovno potvrđuje ranije iznesen uvid da majčinstvo, kao sastavni element proširenog okvira 5M, nije rubna ni individualna okolnost, nego strukturna sastavnica koja sustavno oblikuje poduzetničke izbore, obrasce umrežavanja i pristup kapitalu.

Uspjeh žena u poduzetništvu u velikoj mjeri ovisi o kvaliteti i dostupnosti institucionalnog okruženja. Institucije su kao posrednici između poduzetnika i tržišta sposobne ublažiti učinke rodne nejednakosti kada su oblikovane uključivo i prilagođeno različitim skupinama poduzetnika (Brush, Bruin i Welter, 2009). Ciljano oblikovane politike, subvencije, savjetodavne usluge i poslovni inkubatori mogu ublažiti sustavne prepreke koje nerazmjerno pogađaju žene, osobito u ranim fazama poslovanja (Marlow i McAdam, 2013). U Hrvatskoj su glavni nositelji potpora Hrvatska agencija za malo gospodarstvo, inovacije i investicije (HAMAG-BICRO), Hrvatska banka za obnovu i razvitak (HBOR) te Hrvatski zavod za zapošljavanje (HZZ) čija je mjera samozapošljavanja mnogim ženama čest prvi korak prema poduzetništvu. Ipak, literatura upozorava da velika dostupnost instrumenata potpore sama po sebi ne jamči njihovu djelotvornost. Potpora se u Hrvatskoj često provodi kroz generičke mjere čija je prilagodba specifičnim potrebama poduzetnica i dalje ograničena (Zirdum i Cvitanović, 2017).

# 3. ISTRAŽIVAČKI OKVIR

Empirijski cilj istraživanja jest razumjeti dinamiku ženskog poduzetništva u Hrvatskoj analizom profila, motiva i prepreka s kojima se susreću poduzetnice te procjenom njihove percepcije djelotvornosti postojećih oblika potpore. Primarno istraživanje provedeno je anketnim ispitivanjem. Istraživački instrument bio je strukturirani upitnik izrađen u alatu Google Forms koji je sadržavao dvadeset i pet pitanja raspoređenih u šest tematskih cjelina: osnovni demografski i poslovni podaci; motivacija za ulazak u poduzetništvo; izvori financiranja i prepreke financiranju; izazovi u vođenju poslovanja; uključenost u mreže i udruge poduzetnica; te korištenje institucionalne potpore. Pitanja zatvorenog tipa, prikladna za kvantitativnu analizu, kombinirana su s otvorenim pitanjima koja su omogućila kvalitativni uvid, čime je iskustvo poduzetnica sagledano iz više perspektiva.

Upitnik je bio namijenjen isključivo ženama koje su vlasnice mikro, malih ili srednjih poduzeća registriranih u Republici Hrvatskoj. Distribuiran je tijekom jednomjesečnog razdoblja potkraj ljeta 2025. godine putem mreža i organizacija poduzetnica te ciljanim elektroničkim putem korištenjem kontakata iz baze HAMAG-BICRO-a. Sudjelovanje je bilo dobrovoljno i anonimno, a prosječno vrijeme ispunjavanja upitnika iznosilo je približno deset minuta. Od ukupno 220 prikupljenih odgovora, u analizi je zadržan 191 odgovor. Uključene su samo ispitanice koje su u trenutku provođenja ankete potvrdile aktivan poduzetnički status, dok su preostali odgovori isključeni, čime je osigurana relevantnost uzorka za predmet istraživanja. Uzorak je oblikovan neprobabilističkim postupkom koji je kombinirao namjerno i prigodno uzorkovanje putem opisanih distribucijskih kanala. Stoga uzorak nije slučajno odabran iz populacije poduzetnica, a nalazi se ne mogu generalizirati na cjelokupnu populaciju žena poduzetnica u Hrvatskoj. Podaci su obrađeni kvantitativnim metodama u dvije faze. U prvoj, deskriptivnoj fazi, utvrđen je sastav uzorka i raspodjela odgovora. U drugoj, komparativnoj fazi, ispitivane su razlike prema regiji, sektoru i veličini poduzeća primjenom križnih tabulacija. Kod pojedinih pitanja bilo je moguće odabrati više odgovora zbog čega se pripadajući postotci preklapaju i njihov zbroj ne iznosi nužno sto posto. Tri su hipoteze promatrane kao empirijski provjerljive tvrdnje i ocjenjivane na temelju utvrđenih distribucija odgovora: za prvu hipotezu prema rangiranju prijavljenih prepreka, za drugu prema relativnoj učestalosti navedenih motiva, a za treću prema raspodjeli ocjena zadovoljstva i odgovorima na otvorena pitanja. Istraživanje je presječnog karaktera, a

mjere se temelje na samoprocjeni ispitanica. Analiza stoga utvrđuje povezanosti na razini uzorka, a ne uzročno-posljedične učinke na razini pojedinca.

Istraživanje je vođeno trima hipotezama:

- **H1:** Poduzetnice smatraju ograničen pristup financiranju najvažnijom preprekom.
- **H2:** Dominantan motiv za ulazak u poduzetništvo jest želja za neovisnošću i autonomijom.
- **H3:** Institucionalna potpora ne percipira se kao dostatna za razvoj ženskog poduzetništva.

# 4. REZULTATI ISTRAŽIVANJA

Rezultati empirijskog istraživanja ženskog poduzetništva u Hrvatskoj obuhvaćaju analizu osnovnih sociodemografskih i poslovnih obilježja ispitanica, njihovu motivaciju za ulazak u poduzetništvo, izvore financiranja i ključne prepreke poslovanju, iskustva s institucionalnom potporom te očekivanja od mreža i udruga poduzetnica. Nalazi se tumače u odnosu na tri postavljene hipoteze, uz uvažavanje ograničenja istraživačkog dizajna. S obzirom na to da se podaci temelje na samoprocjeni ispitanica, rezultati ponajprije prikazuju obrasce iskustava i percepcija unutar promatranog uzorka.

Od ukupno 220 vraćenih upitnika, 191 je bio valjan za analizu. Analiza dobne strukture pokazuje da je poduzetništvo za žene u Hrvatskoj najčešće odluka koja se donosi u fazi profesionalne zrelosti. U uzorku nema nijedne poduzetnice mlađe od dvadeset godina. Dobna skupina od 21 do 30 godina čini 4,7 % uzorka, skupina od 31 do 40 godina 20,9 %, dok najbrojniju skupinu čine ispitanice u dobi od 41 do 50 godina, s udjelom od 39,8 %. Žene starije od pedeset godina čine 34,6 % uzorka.

Dob u trenutku osnivanja poslovnog pothvata pomaknuta je približno deset godina prema mlađim dobnim skupinama. Poslovanje je između 31. i 40. godine života pokrenulo 41,9 % ispitanica, a između 21. i 30. godine njih 31,4 %. To znači da je više od 70 % ispitanica u poduzetništvo ušlo prije četrdesete godine života. Promatraju li se ti podaci zajedno s trajanjem poslovanja, pri čemu četvrtina ispitanica posluje od jedanaest do dvadeset godina, a dodatna

četvrtina od šest do deset godina, može se zaključiti da poduzetništvo za većinu ispitanica nije privremeno ili epizodično radno rješenje, nego dugoročno profesionalno usmjerenje.

Obrazovna struktura ispitanica izrazito je povoljna te predstavlja jedno od važnih obilježja promatrane populacije. Gotovo dvije trećine ispitanica ima visoku razinu obrazovanja: 42,4 % završilo je diplomski ili specijalistički studij, a dodatnih 23,0 % posjeduje poslijediplomsku kvalifikaciju. Srednju školu završilo je 22,5 % ispitanica, dok 12,0 % ima stručni ili prijediplomski studij. Visoka zastupljenost obrazovanih žena u skladu je s kognitivnim, upravljačkim i relacijskim zahtjevima vlasništva nad poduzećem. Istodobno, prisutnost poduzetnica s nižom razinom formalnog obrazovanja pokazuje da je visoko obrazovanje čest, ali ne i nužan preduvjet za ulazak u poduzetništvo.

**Tablica 1. Demografski profil žena poduzetnica (trenutačna dob, dob pri pokretanju, obrazovanje)**

| Trenutačna dob | Udio | Dob pri pokretanju / Obrazovanje | Udio |
|---|---|---|---|
| 21–30 | 4,7 % | Pokretanje: do 20 | 3,7 % |
| 31–40 | 20,9 % | Pokretanje: 21–30 | 31,4 % |
| 41–50 | 39,8 % | Pokretanje: 31–40 | 41,9 % |
| Iznad 50 | 34,6 % | Pokretanje: 41–50 | 18,8 % |
| – | – | Pokretanje: iznad 50 | 4,2 % |
| Obrazovanje: srednja škola | 22,5 % | Stručni / preddiplomski | 12,0 % |
| Diplomski / specijalistički | 42,4 % | Poslijediplomski | 23,0 % |

Izvor: Izračun autora na temelju podataka prikupljenih anketom (n = 191).

Prostorna raspodjela uzorka pokazuje izraženu koncentraciju poduzetnica u Gradu Zagrebu i obalnim područjima Hrvatske. Grad Zagreb obuhvaća 45 % ispitanica, odnosno 86 žena, dok primorska Hrvatska čini dodatnih 26 % uzorka, odnosno 50 ispitanica. Središnja Hrvatska zastupljena je s 24 ispitanice, odnosno 13 %, istočna Hrvatska sa 16 ispitanica, odnosno 8 %, a sjeverna Hrvatska s 15 ispitanica, također 8 %. Takav obrazac u velikoj mjeri odražava šire regionalne razlike u intenzitetu poduzetničke aktivnosti i gospodarskoj razvijenosti u Hrvatskoj. Prema mjestu poslovanja, 78 % poduzeća djeluje u urbanim sredinama, a 22 % u ruralnim područjima. Prema

veličini poduzeća, izrazito prevladavaju mikropoduzeća. Njih 152, odnosno 79,6 %, zapošljava manje od deset osoba; 36 ispitanica, odnosno 18,8 %, vodi mala poduzeća, dok samo tri ispitanice, odnosno 1,6 %, vode srednja poduzeća. Takva struktura upućuje na ograničenja rasta i širenja poduzeća u vlasništvu žena, ali istodobno potvrđuje da je žensko poduzetništvo u Hrvatskoj dominantno ukorijenjeno u segmentu mikro i malih poslovnih subjekata.

**Tablica 2. Obilježja poslovanja (regija, lokacija, veličina poduzeća)**

| Obilježje | Broj | Udio |
|---|---|---|
| Regija: Grad Zagreb | 86 | 45 % |
| Regija: primorska Hrvatska | 50 | 26 % |
| Regija: središnja Hrvatska | 24 | 13 % |
| Regija: istočna Hrvatska | 16 | 8 % |
| Regija: sjeverna Hrvatska | 15 | 8 % |
| Lokacija: urbana | – | 78 % |
| Lokacija: ruralna | – | 22 % |
| Veličina: mikro (<10 zaposlenih) | 152 | 79,6 % |
| Veličina: malo (10–49) | 36 | 18,8 % |
| Veličina: srednje (50–249) | 3 | 1,6 % |

Izvor: Izračun autora na temelju podataka prikupljenih anketom (n = 191).

Prema djelatnostima, uzorak je dominantno koncentriran u uslužnom sektoru. Ostale uslužne djelatnosti obuhvaćaju gotovo trećinu ispitanica, odnosno 29,3 %. Slijede prerađivačka industrija s 13,1 %, administrativne i pomoćne uslužne djelatnosti sa 7,9 %, djelatnosti pružanja smještaja te pripreme i usluživanja hrane sa 7,9 %, stručne, znanstvene i tehničke djelatnosti sa 7,3 % te trgovina na veliko i malo sa 6,8 %. Premda je njihov udio još uvijek skroman, prisutnost žena u prerađivačkoj industriji, građevinarstvu, informacijama i komunikacijama te prometu upućuje na postupno širenje poduzetničke aktivnosti žena i na sektore koji se tradicionalno percipiraju kao pretežito muški. Budući da je istraživanjem obuhvaćeno svako područje Nacionalne klasifikacije djelatnosti, usklađene s klasifikacijom NACE Rev.

2, struktura uzorka omogućuje međusektorsku usporedbu, a ne samo parcijalni uvid u pojedine djelatnosti.

**Tablica 3. Ispitanice prema sektoru djelatnosti (NKD / NACE)**

| Sektor djelatnosti | Broj | Udio |
|---|---|---|
| Ostale uslužne djelatnosti | 56 | 29,3 % |
| Prerađivačka industrija | 25 | 13,1 % |
| Administrativne i pomoćne uslužne djelatnosti | 15 | 7,9 % |
| Pružanje smještaja te priprema i usluživanje hrane | 15 | 7,9 % |
| Stručne, znanstvene i tehničke djelatnosti | 14 | 7,3 % |
| Trgovina na veliko i na malo; popravak vozila | 13 | 6,8 % |
| Djelatnosti zdravstvene zaštite i socijalne skrbi | 11 | 5,8 % |
| Poljoprivreda, šumarstvo i ribarstvo | 10 | 5,2 % |
| Obrazovanje | 9 | 4,7 % |
| Financijske djelatnosti i osiguranje | 7 | 3,7 % |
| Građevinarstvo | 5 | 2,6 % |
| Informacije i komunikacije | 4 | 2,1 % |
| Umjetnost, zabava i rekreacija | 4 | 2,1 % |
| Prijevoz i skladištenje | 3 | 1,6 % |

Izvor: Izračun autora na temelju podataka prikupljenih anketom (n = 191).

Motivacijska struktura poduzetnica oblikovana je prije svega željom za autonomijom, prepoznavanjem poslovne prilike i potrebom za većom organizacijskom fleksibilnošću, dok je nužnost prisutna, ali podređena tim motivima. Taj je nalaz izravno relevantan za drugu hipotezu. Kod pitanja s mogućnošću višestrukog odabira, želja za neovisnošću bila je najsnažniji poticaj za ulazak u poduzetništvo. Navelo ju je 126 ispitanica, odnosno 66,0 %. Slijede prepoznata poslovna prilika, koju je navelo 59 ispitanica, odnosno 30,9 %, fleksibilnost radnog vremena s 58 ispitanica, odnosno 30,4 %, te potreba za dodatnim prihodom koju je navelo 50 ispitanica, odnosno 26,2 %. Obiteljska tradicija, koju su navele 34 ispitanice, odnosno 17,8 %, i nemogućnost pronalaska zaposlenja, koju je navelo 26 ispitanica, odnosno 13,6 %, pojavljuju se znatno rjeđe.

Kada su ispitanice trebale odrediti glavni poticaj za ulazak u poduzetništvo, njih 52,9 % navelo je kombinaciju prilike i nužnosti, 35,1 % isključivo priliku, a samo 12,0 % isključivo nužnost. Komponenta prilike stoga je prisutna u 88 % odluka o ulasku u poduzetništvo. Osobne vrijednosti, uključujući ravnotežu poslovnog i privatnog života te doprinos lokalnoj zajednici, bile su odlučujuće za 33,5 % ispitanica, dok su za daljnjih 53,9 % imale umjerenu važnost.

**Tablica 4. Motivacija za ulazak u poduzetništvo (višestruki odabir) i glavni poticaj**

| Motiv / glavni poticaj | Broj | Udio |
|---|---|---|
| Želja za samostalnošću | 126 | 66,0 % |
| Uočena poslovna prilika | 59 | 30,9 % |
| Fleksibilnost radnog vremena | 58 | 30,4 % |
| Dodatni prihodi | 50 | 26,2 % |
| Obiteljska tradicija / nasljeđivanje | 34 | 17,8 % |
| Nemogućnost zapošljavanja | 26 | 13,6 % |
| Poticaj: kombinacija prilike i nužde | – | 52,9 % |
| Poticaj: samo prilika | – | 35,1 % |
| Poticaj: samo nužda | – | 12,0 % |

Izvor: Izračun autora na temelju podataka prikupljenih anketom (n = 191). Pitanja s višestrukim odabirom ne zbrajaju se na 100 %.

Na temelju takvog obrasca moguće je razlikovati tri osnovna profila poduzetnica. Prvu skupinu čine poduzetnice vođene prilikom i željom za autonomijom. Drugu čine poduzetnice koje se mogu opisati kao hibridne pragmatičarke: one istodobno reagiraju na poslovnu priliku i na okolnosti nužnosti, a njihove su odluke pritom snažno oblikovane osobnim vrijednostima. Treću skupinu čini manjina poduzetnica koje u poslovanje ulaze prije svega zbog nužnosti, pri čemu su njihovi pothvati češće izloženi ograničenjima resursa. Nužnost može djelovati kao početni poticaj, ali odluka o ulasku u poduzetništvo najčešće sazrijeva tek kada se pojavi održiva poslovna prilika i mogućnost organiziranja rada u skladu s osobnim i obiteljskim okolnostima.

Struktura početnog kapitala dominantno se oslanja na vlastite resurse, koje je navelo 149 ispitanica, odnosno 78,0 %. Riječ je o jasnom obrascu financijskog oslanjanja na vlastite izvore, odnosno financijskog *bootstrappinga* (Winborg i Landström, 2001) koji je u skladu s prevladavanjem mikropoduzeća i izraženom orijentacijom prema autonomiji. Najčešći dopunski izvori bili su pomoć obitelji i prijatelja, koju su navele 53 ispitanice, odnosno 27,7 %, potpore Hrvatskog zavoda za zapošljavanje i fondovi Europske unije, koje je navelo 48 ispitanica, odnosno 25,1 %, te bankovni krediti, koje je navelo 46 ispitanica, odnosno 24,1 %. Investitori i poslovni anđeli, koje je navelo samo šest ispitanica, odnosno 3,1 %, te specijalizirane razvojne institucije, HAMAG-BICRO i HBOR, pojavljuju se tek rubno.

**Tablica 5. Izvori financiranja pokretanja poslovanja (višestruki odabir)**

| Izvor financiranja | Broj | Udio |
|---|---|---|
| Vlastita sredstva | 149 | 78,0 % |
| Pomoć obitelji / prijatelja | 53 | 27,7 % |
| Potpore (HZZ / EU fondovi) | 48 | 25,1 % |
| Bankovni kredit | 46 | 24,1 % |
| Investitori / poslovni anđeli | 6 | 3,1 % |
| Preuzimanje / nasljeđivanje posla | 4 | 2,1 % |
| HAMAG-BICRO instrumenti | 2 | 1,0 % |
| HBOR | 1 | 0,5 % |

Izvor: Izračun autora na temelju podataka prikupljenih anketom (n = 191). Pitanja s višestrukim odabirom ne zbrajaju se na 100 %.

Nešto više od polovice ispitanica, njih 53,4 %, početno je poslovanje financiralo iz jednog izvora, dok je 46,6 % koristilo kombinirane strukture financiranja. U tim su se strukturama vlastitim sredstvima najčešće pridodavali pomoć obitelji i prijatelja, bankovni kredit ili neki oblik potpore. Takav slijed nalaza upućuje na to da poduzetnice početni poslovni rizik prvenstveno preuzimaju vlastitim sredstvima, dok dodatne izvore aktiviraju tek kako rastu potrebe poslovanja. Potpore pritom imaju funkciju ublažavanja rizika i poticanja privatnog ulaganja, a ne njegove potpune zamjene. Rizični kapital i razvojno financiranje ostaju ograničeni na mali broj slučajeva, što

može upućivati na informacijske i proceduralne prepreke, jednako kao i na profil ili veličinu samih poslovnih projekata. Analiza rangiranja prijavljenih prepreka predstavlja izazov u dokazivanju prve hipoteze. Dominantna poteškoća jest administrativno i birokratsko opterećenje, koje je navelo 67,0 % ispitanica, odnosno 128 od 191 ispitanice. Slijedi usklađivanje poslovnog i privatnog života, koje je navelo 48,2 % ispitanica, odnosno njih 92. Ograničen pristup kapitalu nalazi se tek na trećem mjestu, s udjelom od 37,7 %, odnosno 72 od 191 ispitanice. Nakon toga slijede nedostatak potpore, koji je navelo 28,3 % ispitanica, odnosno njih 54, rodni stereotipi i društvena očekivanja, koje je navelo 17,3 % ispitanica, odnosno njih 33, te nedostatak poslovnih kontakata, koji je navelo 16,8 % ispitanica, odnosno njih 32. Otvoreni odgovori o čestim promjenama propisa, nelojalnoj konkurenciji, nedostatku radne snage i slabostima računovodstvene funkcije dodatno potvrđuju zaključak da su ključne prepreke koje poduzetnice doživljavaju proceduralne i operativne, a ne isključivo financijske.

**Tablica 6. Prijavljene prepreke u vođenju poslovanja (višestruki odabir)**

| Prepreka | Broj | Udio |
|---|---|---|
| Administrativno-birokratsko opterećenje | 128 | 67,0 % |
| Usklađivanje poslovnog i privatnog života | 92 | 48,2 % |
| Otežan pristup kapitalu | 72 | 37,7 % |
| Nedostatak podrške | 54 | 28,3 % |
| Rodni stereotipi i društvena očekivanja | 33 | 17,3 % |
| Izostanak poslovnih kontakata | 32 | 16,8 % |

Izvor: Izračun autora na temelju podataka prikupljenih anketom (n = 191). Pitanja s višestrukim odabirom ne zbrajaju se na 100 %.

Takva konfiguracija nalaza nije proturječna, nego međusobno konzistentna. Administrativna složenost i regulatorna nestabilnost povećavaju transakcijske troškove te vremensku neizvjesnost pri korištenju instrumenata koji zahtijevaju formalizirane postupke. To može potaknuti oslanjanje na samofinanciranje i kombinacije vlastitih sredstava s potporama. Percipirani manjak kapitala, dodatno otežan nedovoljno razvijenim poslovnim mrežama, može smanjiti kreditnu sposobnost pothvata u ranoj fazi te objasniti ograničenu zastupljenost dužničkog, a osobito vlasničkog financiranja.

Zahtjevi usklađivanja poslovnog i obiteljskog života povećavaju sklonost izvorima financiranja s manje rigidnim uvjetima otplate i nadzora, u odnosu na strože režime zaduživanja ili vlasničkog financiranja. Operativne slabosti istodobno mogu smanjiti kvalitetu dokumentacije potrebne za pristup institucionalnim izvorima financiranja. Rodni stereotipi djeluju i neizravno, kroz evaluacijsku pristranost u odnosima s kreditorima i investitorima, što je mehanizam potvrđen i u široj literaturi (Kanze i sur., 2018). Gotovo tri četvrtine ispitanica, njih 73,8 %, odnosno 141 od 191 ispitanice, koristilo je neki oblik institucionalne potpore. Među navedenim oblicima potpore dominiraju nacionalne institucije: HAMAG-BICRO čini 44,6 % navoda, Hrvatski zavod za zapošljavanje 29,7 %, a HBOR 7,9 %. Instrumenti uvedeni tijekom pandemije bolesti COVID-19 čine 5,4 % navoda, dok se izravna upućivanja na fondove Europske unije pojavljuju u 3,0 % slučajeva. Ocjene zadovoljstva, međutim, kreću se između neutralnih i umjereno pozitivnih. Udio ocjena četiri i pet zajedno iznosi 37,2 %, dok ocjene jedan i dva čine 28,3 %, uz značajan udio neutralnih odgovora.

**Tablica 7. Korištenje institucionalne podrške, zadovoljstvo i očekivana uloga udruga**

| Pokazatelj | Udio |
|---|---|
| Koristile neki oblik institucionalne podrške | 73,8 % |
| Navedeni nositelj: HAMAG-BICRO | 44,6 % |
| Navedeni nositelj: HZZ | 29,7 % |
| Navedeni nositelj: HBOR | 7,9 % |
| Zadovoljstvo visoko (ocjene 4–5) | 37,2 % |
| Zadovoljstvo nisko (ocjene 1–2) | 28,3 % |
| Udruge bi trebale: utjecati na politike | 67 % |
| Udruge bi trebale: pružati financijske i savjetodavne usluge | 65 % |
| Udruge bi trebale: promicati žensko poduzetništvo | 65 % |
| Udruge bi trebale: pružati edukaciju i mentorstvo | 59 % |
| Udruge bi trebale: omogućiti međunarodno umrežavanje | 50 % |

Izvor: Izračun autora na temelju podataka prikupljenih anketom (n = 191).

Visoka dostupnost institucionalne potpore tako istodobno postoji uz neujednačenu kvalitetu korisničkog iskustva. Taj je raskorak u skladu s često

isticanim administrativnim opterećenjem te je izravno povezan s trećom hipotezom. Otvoreni odgovori koncentriraju kritike oko triju područja: postupaka, dostupnosti informacija i uvjeta financiranja. Ispitanice navode prekomjernu i rascjepkanu administraciju, složene prijavne postupke, dugo trajanje evaluacije i isplate sredstava te fragmentiranost informacija, zbog koje je odgovarajući oblik potpore teško pronaći bez pomoći savjetnika, osobito izvan većih urbanih središta. Kada je riječ o financijskim uvjetima, ispitanice ističu zahtjeve vezane uz kreditne kolaterale, visoke kamatne stope, kratke rokove otplate te strukturni raskorak između potreba mikropoduzetničkih subjekata i načina na koji su instrumenti potpore oblikovani. Mnogi su instrumenti vezani uz zapošljavanje ili digitalizaciju te nisu primjenjivi na male samostalne djelatnosti i paušalne obrte. Posebno se izdvaja pitanje nedostatne zaštite majčinstva. Rodiljni i roditeljski dopust, bolovanja te status paušalnih obrtnica navode se kao sustavni nedostaci koji mogu ugroziti kontinuitet poslovanja.

Uključenost u formalne mreže potpore razmjerno je niska, premda se poduzetnice koje u njima sudjeluju najčešće povezuju s organizacijama čiji programi pružaju upravo one resurse koji su ključni za rast poslovanja. Na pitanje koju bi ulogu udruge trebale preuzeti, ispitanice su najčešće navodile utjecaj na oblikovanje javnih politika, što je istaknulo 67 % ispitanica, pružanje financijskih i savjetodavnih usluga, koje je navelo 65 %, te javnu promociju ženskog poduzetništva, također sa 65 %. Slijede obrazovanje i mentorstvo s 59 % te međunarodno umrežavanje s 50 %. Takav redoslijed pozicionira udruge kao važan most između javnih politika i konkretne poduzetničke prakse.

Ukupno promatrano, nalazi omogućuju sljedeću ocjenu triju hipoteza. Prva hipoteza, prema kojoj poduzetnice ograničen pristup financiranju smatraju najvažnijom preprekom, nije potvrđena. Pristup kapitalu nalazi se tek na trećem mjestu među prijavljenim preprekama, iza administrativnog opterećenja i teškoća usklađivanja poslovnog i privatnog života. Hipoteza se stoga u izvorno postavljenom obliku odbacuje. Druga hipoteza, koja pretpostavlja da je želja za neovisnošću i autonomijom dominantan motiv za ulazak u poduzetništvo, potvrđena je. Želja za neovisnošću najčešće je navođen pojedinačni motiv, a komponenta prilike prisutna je u velikoj većini odluka o pokretanju poslovanja. Treća hipoteza, prema kojoj se institucionalna potpora ne percipira kao dostatna za razvoj ženskog poduzetništva, također je potvrđena. Unatoč visokoj stopi korištenja dostupnih oblika potpore, razina zadovoljstva tek je umjerena, dok

kvalitativni nalazi ukazuju na izraženo nezadovoljstvo postupcima, informacijama i usklađenošću instrumenata s potrebama mikropoduzeća. Budući da se analiza temelji na distribucijama učestalosti unutar jednoga neprobabilističkog uzorka, zaključci opisuju strukturu odgovora u promatranom uzorku. Oni stoga ne omogućuju generalizaciju na ukupnu populaciju poduzetnica u Hrvatskoj niti donošenje uzročno-posljedičnih zaključaka.

# 5. DISKUSIJA

Profil poduzetnica obuhvaćenih istraživanjem u velikoj je mjeri podudaran s obrascima koje bilježi međunarodna literatura, ali istodobno pokazuje neke naglašene značajke hrvatskoga konteksta. U uzorku prevladavaju žene zrelije životne dobi, s relativno visokom razinom obrazovanja koje posluju u urbanim sredinama i vode mikropoduzeća, najčešće u uslužnim djelatnostima. Takva struktura odgovara nalazima OECD-a i Global Entrepreneurship Monitora prema kojima se žene češće uključuju u djelatnosti s nižom dodanom vrijednošću, manjim početnim kapitalnim zahtjevima i ograničenim mogućnostima brzog širenja poslovanja. Međutim, takva sektorska koncentracija ne bi se smjela tumačiti kao pokazatelj manjka poduzetničkih ambicija ili sposobnosti. Ona prije odražava okolnosti u kojima žene pokreću i vode poslovanje: dostupnost početnog kapitala, obiteljske obveze, potrebu za većom vremenskom fleksibilnošću, ali i ograničen pristup poslovnim mrežama i informacijama. U tom smislu, prevlast mikropoduzeća može se promatrati i kao racionalan odgovor na uvjete u kojima poduzetnice posluju, a ne samo kao razvojno ograničenje. Mikropoduzeće omogućuje veću kontrolu nad radnim vremenom, postupno preuzimanje rizika i prilagodbu poslovanja osobnim i obiteljskim okolnostima, ali istodobno može ograničiti mogućnost zapošljavanja, investiranja i dugoročnog rasta.

Motivacijska struktura dodatno potvrđuje da ulazak žena u poduzetništvo nije prvenstveno posljedica nužde. Najvažniji pojedinačni poticaj bila je želja za neovisnošću, dok su poslovna prilika i fleksibilnost radnog vremena također imali izraženu ulogu. Nužnost se pojavljuje kao relevantan, ali rjeđi motiv. Većina ispitanica svoje je odluke opisala kao spoj prepoznate prilike i životnih ili profesionalnih okolnosti koje su ih potaknule na samostalni poslovni pothvat. Drugim riječima, poduzetništvo se za velik dio ispitanica ne pojavljuje kao krajnje rješenje nakon neuspjeha na tržištu rada, nego kao

način ostvarivanja veće autonomije, profesionalnog razvoja i mogućnosti da se poslovni život organizira u skladu s osobnim vrijednostima. Takvo tumačenje u skladu je s nalazima drugih istraživanja: onih koji upozoravaju na važnost suradničke, vrijednosne i društveno osjetljive dimenzije poduzetničke motivacije žena (Zisser i sur., 2019) i onih koji zaključuju da žensko poduzetništvo nije usmjereno isključivo na maksimizaciju dobiti nego i na postizanje ravnoteže između poslovne neovisnosti, osobnog ispunjenja i privatnog života (Goffee i Scase, 1985). To ne znači da žene manje vrednuju poslovni uspjeh, rast ili financijsku sigurnost. Prije se može reći da uspjeh češće procjenjuju kroz širi skup kriterija koji uz poslovne rezultate uključuju kvalitetu života, kontrolu nad vlastitim vremenom, stabilnost obitelji i doprinos neposrednoj zajednici.

Najvažniji rezultat istraživanja odnosi se na drukčiji poredak prepreka od onoga koji se često pretpostavlja u raspravama o ženskom poduzetništvu. Administrativno i birokratsko opterećenje ispitanice najčešće navode kao ključan problem, dok se teškoće usklađivanja poslovnih i obiteljskih obveza pojavljuju prije ograničenog pristupa kapitalu. Taj nalaz ne znači da financiranje nije problem. Naprotiv, struktura početnog financiranja pokazuje izrazito oslanjanje na vlastita sredstva, pomoć obitelji i prijatelja te ograničeno korištenje formalnih financijskih izvora. Međutim, poduzetnice očigledno ne doživljavaju financijski problem samo kao nedostatak novca, nego kao posljedicu složenijih okolnosti koje otežavaju dolazak do kapitala.

Riječ je ponajprije o složenim postupcima prijave, dugim rokovima obrade zahtjeva, neujednačenoj dostupnosti informacija, zahtjevima u vezi s kolateralom i dokumentacijom te nedovoljnoj prilagođenosti postojećih instrumenata potrebama mikropoduzeća. Kada su informacije raspršene, postupci nejasni, a pravila promjenjiva, poduzetnice će se češće oslanjati na vlastite izvore, čak i kada su oni nedostatni za ozbiljniji rast poslovanja. U takvim okolnostima financijska ograničenja ne nestaju, nego se pojavljuju kao dio šireg institucionalnog problema. Kapital može formalno postojati, ali ostati praktično teško dostupan onima koji nemaju dovoljno vremena, specijaliziranog znanja ili savjetodavne podrške da prođu kroz zahtjevne administrativne procedure. Odbacivanje prve hipoteze stoga ne bi trebalo tumačiti kao potvrdu da je financiranje ženama poduzetnicama dostatno i lako dostupno. Ono prije pokazuje da se, iz perspektive samih ispitanica, ključna prepreka nalazi prije samog pristupa novcu: u transakcijskim troškovima sustava potpore, administrativnoj složenosti i nedostatno razvijenoj infrastrukturi koja bi omogućila lakše usklađivanje poslovnog i obiteljskog

života. Posebno je važno to što su ispitanice pitanje zaštite majčinstva, rodiljnih i roditeljskih prava, bolovanja te statusa paušalnih obrtnica prepoznale kao sustavni problem. Takve okolnosti mogu ugroziti kontinuitet poslovanja upravo u razdobljima kada je poduzetnica najranjivija i kada joj je institucionalna zaštita najpotrebnija.

Hrvatski slučaj time dodatno potvrđuje argument da se žensko poduzetništvo ne može objasniti samo tržištem, novcem i menadžmentom. Majčinstvo, obiteljske obveze, društvena očekivanja te makroinstitucionalno i mezoinstitucionalno okruženje moraju biti sastavni dio analitičkog okvira (Bruin, Brush i Welter, 2007). U iskustvu ispitanica upravo su problemi usklađivanja poslovnog i privatnog života te administrativne i institucionalne prepreke izraženiji od klasično shvaćenog nedostatka kapitala. To pokazuje da žensko poduzetništvo nije moguće razumjeti kroz jednu izoliranu prepreku, nego kroz međudjelovanje poslovnih, institucionalnih, društvenih i osobnih čimbenika.

Žene u poduzetništvo uglavnom ulaze zbog želje za neovisnošću, profesionalnim ostvarenjem i prepoznatom poslovnom prilikom. Istodobno, institucionalnu potporu ne doživljavaju kao dovoljno prilagođenu njihovim potrebama. Problem, dakle, nije u nedostatku poduzetničke motivacije, niti isključivo u nedostatku sredstava, nego u raskoraku između potreba poduzetnica i načina na koji su oblikovani instrumenti potpore, financijski proizvodi, administrativni postupci i javne usluge. Iz toga proizlazi potreba za diferenciranim pristupom javnim politikama. Poduzetnicama koje u poslovanje ulaze na temelju prepoznate prilike i imaju potencijal rasta potrebno je osigurati kvalitetnije mentorstvo, pristup poslovnim mrežama, specijalizirano savjetovanje i financijske instrumente koji mogu podržati širenje poslovanja. Za poduzetnice koje poduzetništvo pokreću kombinacijom prilike i nužnosti važna je povezanost financijske i organizacijske potpore: fleksibilniji kreditni proizvodi, dostupne savjetodavne usluge, programi usavršavanja te pouzdane usluge skrbi o djeci i drugim članovima obitelji. Poduzetnicama koje u poslovanje ulaze prvenstveno iz nužnosti potrebni su instrumenti koji smanjuju početni rizik, poput mikrokredita, jamstvenih shema, poslovnih inkubatora i kontinuirane stručne potpore u prvim godinama poslovanja.

Bez obzira na razlike među pojedinim skupinama, nekoliko je prioriteta zajedničko. Potrebno je pojednostavniti i standardizirati postupke prijave za potpore i financiranje, skratiti rokove odlučivanja, osigurati veću

predvidljivost natječajnih ciklusa te objediniti relevantne informacije na jednome, lako dostupnom mjestu. Jednako je važno razviti savjetodavne usluge koje neće biti usmjerene samo na pripremu projektne dokumentacije nego i na dugoročno jačanje upravljačkih, financijskih i razvojnih kapaciteta poduzetnica. Zaštitu majčinstva i dostupnost društvene infrastrukture skrbi pritom treba promatrati kao sastavni dio poduzetničke politike. Kada poduzetnica zbog roditeljstva, bolesti ili skrbi za člana obitelji nema mogućnost privremenog povlačenja iz svakodnevnog poslovanja bez ozbiljnog ugrožavanja prihoda i opstanka poduzeća, riječ je o prepreci koja izravno utječe na poduzetničku aktivnost, zapošljavanje i gospodarski rast. U tom smislu, potpora ženskom poduzetništvu ne može se svesti na povremene subvencije i natječaje. Ona zahtijeva dosljednije povezivanje gospodarske politike, politike zapošljavanja, socijalne politike i rodne ravnopravnosti.

## 6. ZAKLJUČAK

Žensko poduzetništvo u Hrvatskoj dinamično je, ali još uvijek nedovoljno iskorišteno razvojno područje koje povezuje gospodarske, sociokulturne i institucionalne dimenzije. Empirijski nalazi prikazani u ovom radu izdvajaju populaciju zrelijih i visokoobrazovanih žena koje svoje poslovne pothvate najčešće pokreću između tridesete i četrdesete godine života. U pravilu vode mikropoduzeća koncentrirana u urbanim uslužnim djelatnostima, a u poduzetništvo ulaze ponajprije vođene željom za neovisnošću i prepoznatom poslovnom prilikom, a znatno rjeđe zbog nužnosti. Njihovo se financiranje dominantno oslanja na vlastite izvore, a premda gotovo tri četvrtine ispitanica koristi neki oblik institucionalne potpore, razina zadovoljstva tom potporom tek je umjerena. Istraživanje omogućuje izvođenje triju osnovnih zaključaka. Prvo, motiv autonomije ima središnje mjesto u odluci o ulasku u poduzetništvo, dok je ta odluka najčešće povezana s prepoznavanjem poslovne prilike. Takav nalaz upućuje na stvaran potencijal ženskog poduzetništva za rast, inovacije i stvaranje nove vrijednosti. Drugo, institucionalna potpora, premda formalno široko dostupna, još uvijek ne djeluje dovoljno učinkovito zbog administrativne složenosti i nedovoljne prilagođenosti specifičnim potrebama poduzetnica. Treće, suprotno uobičajenoj pretpostavci, poduzetnice kao najveću prepreku ne navode nedostatak kapitala, nego administrativno opterećenje i teškoće usklađivanja poslovnog i obiteljskog života. Pristup financiranju pritom ostaje ozbiljan problem, ali se u percepciji ispitanica nalazi iza navedenih prepreka. Razvoj

ženskog poduzetništva stoga zahtijeva integrirani pristup koji povezuje dostupnost financiranja, fleksibilnost socijalne politike, jačanje znanja i kompetencija te aktivno uključivanje poduzetnica u domaće i međunarodne poslovne mreže.

Iz nalaza proizlazi nekoliko preporuka za one koji oblikuju instrumente potpore. Potrebno je smanjiti administrativna opterećenja i povećati predvidljivost natječajnih ciklusa, osobito u okviru instrumenata Europske unije, Hrvatskog zavoda za zapošljavanje, HAMAG-BICRO-a i HBOR-a. Relevantne informacije trebalo bi objediniti na jedinstvenom digitalnom portalu, uz lokalne kontaktne točke koje bi poduzetnicama pružale jasne i dostupne smjernice. Za mikropoduzeća valja razviti dostupnije mikropotpore, mikrokredite s duljim počekom otplate i jamstvene fondove koji ne bi zahtijevali nerazmjerno opterećujuće oblike kolaterala. Prava samozaposlenih žena tijekom rodiljnog, roditeljskog i bolovanja trebalo bi snažnije približiti pravima zaposlenih žena, dok bi usluge skrbi o djeci i drugim ovisnim članovima obitelji trebale postati dostupniji dio lokalne razvojne infrastrukture. Mentorstvo, specijalizirane poduzetničke akademije i programe umrežavanja potrebno je povezati s financijskom i savjetodavnom potporom kako bi se razvoj kompetencija, poslovne reputacije i tržišnog dosega odvijao istodobno.

Nalaze istraživanja potrebno je tumačiti uz određena ograničenja. Uzorak od 191 poduzetnice oblikovan je neprobabilističkim postupkom, što omogućuje relevantan uvid u profil i iskustva ispitanica, ali ne dopušta potpunu generalizaciju na ukupnu populaciju poduzetnica u Hrvatskoj. Podaci se temelje na samoprocjeni ispitanica, zbog čega je moguće postojanje subjektivnih pristranosti. Buduća bi istraživanja trebala obuhvatiti veći i reprezentativniji uzorak, povezati kvantitativne i kvalitativne metode te longitudinalno pratiti promjene u motivaciji, financiranju i ulozi institucionalne potpore. Dodatnu vrijednost imale bi usporedbe poduzetnica i poduzetnika, kao i analiza razlika među generacijama poduzetnica. Posebnu pozornost trebalo bi posvetiti nedovoljno zastupljenim djelatnostima i ruralnim područjima kako bi se jasnije razumjeli rodni i generacijski obrasci ženskog poduzetništva koje je ovo istraživanje tek počelo ocrtavati.

# LITERATURA

Aldrich, H. E., & Cliff, J. E. (2003). The pervasive effects of family on entrepreneurship: Toward a family embeddedness perspective. Journal of Business Venturing, 18(5), 573-596.

Aldrich, H., Elam, A., & Reese, P. (1996). Strong ties, weak ties, and strangers: Do women business owners differ from men in their use of networking to obtain assistance? In S. Birley & I. McMillan (Eds.), Entrepreneurship in a Global Context (str. 1-25). Routledge.

Bruin, A. de, Brush, C. G., & Welter, F. (2007). Advancing a framework for coherent research on women's entrepreneurship. Entrepreneurship Theory and Practice, 31(3), 323-339.

Brush, C. G., Bruin, A. de, & Welter, F. (2009). A gender-aware framework for women's entrepreneurship. International Journal of Gender and Entrepreneurship, 1(1), 8-24.

Cardella, G. M., Hernández-Sánchez, B. R., & Sánchez-García, J. C. (2020). Women entrepreneurship: a systematic review to outline the boundaries of scientific literature. Frontiers in Psychology, 11, 1557.

Coleman, S., & Robb, A. (2012). Capital structure theory and new technology firms: Is there a match? Management Research Review, 35(2), 106-120.

Global Entrepreneurship Monitor (2024). Women's Entrepreneurship Report 2023/24: Reshaping Economies and Communities. London: GEM.

Global Entrepreneurship Monitor (2025). Women's Entrepreneurship Report 2024/25: Navigating Challenges, Driving Change. London: GEM.

Goffee, R., & Scase, R. (1985). Women in Charge: The Experiences of Female Entrepreneurs. London: Allen & Unwin.

Guzman, J., & Kacperczyk, A. (2019). Gender gap in entrepreneurship. Research Policy, 48(7), 1666-1680.

Hisrich, R. D., & O'Brien, M. (1981). The woman entrepreneur from a business and sociological perspective. In: Frontiers of Entrepreneurship Research. Wellesley, MA: Babson College, 21-39.

Kanze, D., Huang, L., Conley, M. A., & Higgins, E. T. (2018). We ask men to win and women not to lose: closing the gender gap in startup funding. Academy of Management Journal, 61(2), 586-614.

Koziol, K., Schmitz, M., & Bort, S. (2025). Gender differences in entrepreneurial equity financing – a systematic literature review. *Small Business Economics*, 65(1), 231-286.

Marlow, S., & McAdam, M. (2013). Gender and entrepreneurship: advancing debate and challenging myths. International Journal of Entrepreneurial Behaviour & Research, 19(1), 114-124.

OECD (2004). Women's Entrepreneurship: Issues and Policies. Paris: OECD Publishing.

Renzulli, L. A., Aldrich, H., & Moody, J. (2000). Family matters: Gender, networks, and entrepreneurial outcomes. Social Forces, 79(2), 523-546.

Schwartz, E. B. (1976). Entrepreneurship: a new female frontier. Journal of Contemporary Business, 5(1), 47-76.

Winborg, J., & Landström, H. (2001). Financial bootstrapping in small businesses: examining small business managers' resource acquisition behaviours. Journal of Business Venturing, 16(3), 235-254.

World Bank (2024). Women, Business and the Law 2024. Washington, DC: World Bank.

Zirdum, G., & Cvitanović, V. (2017). Prepreke i mogućnosti razvoja ženskog poduzetništva u Republici Hrvatskoj. Obrazovanje za poduzetništvo – E4E, 7(2), 205-222.

Zisser, M. R., Johnson, S. L., Freeman, M. A., & Staudenmaier, P. J. (2019). The relationship between entrepreneurial intent, gender and personality. Gender in Management, 34(8), 665-684.

# STRUCTURAL CHARACTERISTICS, BARRIERS AND DEVELOPMENT PERSPECTIVES OF WOMEN ENTREPRENEURS IN CROATIA: EVIDENCE FROM AN EMPIRICAL SURVEY

***Abstract***

*The paper examines the structural characteristics, barriers and development perspectives of women entrepreneurs in Croatia. It seeks to establish the demographic and business profile of women who own micro, small and medium-sized enterprises, to identify the motives that draw them into self-employment, to rank the obstacles they encounter, and to assess how far the existing institutional support is perceived as adequate. The study rests on a quantitative survey conducted over a one-month period in the late summer of 2025. A structured questionnaire of twenty-five items, organised in six thematic blocks, was distributed through women's entrepreneurial networks and the contact base of the Croatian Agency for SMEs, Innovation and Investments (HAMAG-BICRO). Of 220 responses received, 191 valid cases from active women entrepreneurs were retained and analysed by descriptive and comparative statistics. Women's entrepreneurship in Croatia is predominantly a project of professional maturity: it is concentrated among well-educated women in their forties and fifties, operating micro-enterprises in urban service activities. Opportunity and the desire for independence, rather than necessity, dominate the motivational structure. The most frequently reported obstacle is not access to capital but the administrative and bureaucratic burden, followed by work-family reconciliation. Institutional support is widely used yet only moderately appreciated. Of the three hypotheses, the one identifying finance as the principal barrier is refuted, whereas the hypotheses on the primacy of the autonomy motive and on the perceived insufficiency of institutional support are confirmed. The sample is non-probabilistic and the design cross-sectional, so the findings describe associations within the sample rather than causal effects or population parameters; the data rest on self-assessment. The paper offers recent, sector-wide and region-wide survey evidence on Croatian women entrepreneurs and reorders the conventional hierarchy of barriers, with direct implications for the design of support policy.*

***Keywords:*** *women's entrepreneurship, micro-enterprises, entrepreneurial motivation, barriers to entrepreneurship, institutional support, Croatia.*

JEL klasifikacija: G300
Stručni rad

# AGENCIJSKI TROŠKOVI: IDENTIFICIRANJE TROŠKOVA KOJI NISU U POTPUNOSTI ISKAZANI U FINANCIJSKIM IZVJEŠTAJIMA

Karolina Kokot*
Marina Klačmer Čalopa**

## SAŽETAK

Osnovni odnos koji se promatra u okviru korporativnog upravljanja je odnos menadžer (agent) i vlasnik (principal). Kada su upravljačke i vlasničke strukture odvojene, što je posebno istaknuto u poduzećima veće veličine, posljedica je pojava agencijskih troškova. Neusklađenost interesa menadžera i vlasnika rezultira pojavom agencijskih troškova koji smanjuju vrijednost bogatstva vlasnika, a uz to mogu izravno utjecati na uspješnost poslovanja poduzeća. Iako je cjelokupne agencijske troškove teško kvantificirati, važno ih je prepoznati, a korporativno upravljanje predstavlja najvažniji mehanizam njihova nadzora i mogućeg smanjenja. Ukupne agencijske troškove nije moguće u potpunosti prikazati kao stavke u financijskim izvještajima, pa upravo zato predstavljaju potencijal da postanu značajni troškovi koje poduzeće znatno teže identificira. Cilj rada jest definirati preporuke za

* Dr. sc. socio. Karolina Kokot, Sveučilište u Zagrebu, Fakultet organizacije i informatike, viša asistentica (e-mail: kkokot@foi.unizg.hr), korespondirajući autor.

** Prof. dr. sc. Marina Klačmer Čalopa, Sveučilište u Zagrebu, Fakultet organizacije i informatike, redovita profesorica u trajnom izboru (e-mail: marina.klacmer@foi.unizg.hr).

poduzeća kako identificirati i upravljati agencijskim troškovima kroz primjenu različitih mehanizama korporativnog upravljanja. Rad obuhvaća pregled teorijske i empirijske literature u području agencijskih troškova. Nadalje, definira smjer utjecaja različitih mehanizama korporativnog upravljanja i zamjenskih varijabli putem kojih se agencijski troškovi mjere. Rad doprinosi praksi kroz identifikaciju pokazatelja za prepoznavanje agencijskih troškova i preporuka za njihovo upravljanje. Iako je dio agencijskih troškova prikazan financijskim izvještajima, određena skupina agencijskih troškova nije kvantificirana na takav način, a dugoročno može narušiti učinkovitost poslovanja. Sukladno tome, pitanje agencijskih troškova ne bi trebalo promatrati kao teorijski problem korporativnog upravljanja, već kao praktično pitanje konkurentnosti poslovanja i održivosti poduzeća i upravo u tome je osnova praktičnog doprinosa navedenog rada.

**Ključne riječi:** korporativno upravljanje, mehanizmi korporativnog upravljanja, agencijski troškovi.

# 1. UVOD

Korporativno upravljanje jedan je od nužnih preduvjeta zaštite interesa vlasnika i učinkovitog poslovanja poduzeća. Korporativno upravljanje predstavlja skup nadzornih mehanizama kojima svi dobavljači inputa moraju ostvariti povrate na svoja ulaganja u poduzeće, ali bez ugrožavanja dugoročnog opstanka i prosperiteta poduzeća (Tipurić i sur., 2008). Odvojenost vlasništva i upravljanja, dovodi do rizika neusklađenosti interesa vlasnika i menadžera, što stvara agencijske troškove. Budući da agencijski troškovi mogu negativno utjecati na uspješnost poslovanja i vrijednost poduzeća, važno je razumjeti njihove uzroke, načine identifikacije i mogućnosti smanjenja.

Ciljevi vlasnika i menadžera bit će usklađeni ako poduzeća implementiraju dobru praksu korporativnog upravljanja (Rashid Khan i sur., 2020). Korporativno upravljanje smanjuje agencijske troškove, sprječava oportunističko ponašanje menadžera, nudi okvir za zaštitu interesa dioničara, potiče izvornost i usmjerava poduzeće da djeluje sukladno načelima društvene odgovornosti i održivosti (Tipurić i Cindrić, 2024). Dosadašnja istraživanja pokazuju kako agencijski troškovi imaju negativan učinak na uspješnost poslovanja poduzeća (Rashid Khan i sur., 2020), zbog čega je

važno identificirati mehanizme korporativnog upravljanja kojima je moguće smanjiti navedene troškove.

## 2. AGENCIJSKI TROŠKOVI

Sukob interesa između menadžera i vlasnika generira troškove za poduzeće, a navedeni troškovi su definirani u okviru teorije agenta (Sdiq i Abdullah, 2022), kao najznačajnijega teorijskog okvira korporativnog upravljanja. Agencijski troškovi predstavljaju interne troškove koji su rezultat različitih interesa vlasnika i menadžera, a povezani su s odlukama koje nemaju za cilj maksimizirati profit poduzeća (Huu Nguyen i sur. 2020), već su usmjerene na ciljeve poput povećanja prihoda na godišnjoj razini, koji mogu biti uvjet za ostvarivanje menadžerskih bonusa. Vlasnicima je usklađivanje s interesima menadžera i uvid u poslovne odluke koje menadžeri donose financijski zahtjevno, a kompenzacijski paketi i nadzorni mehanizmi mogu biti neučinkoviti u reduciranju informacijske asimetrije, a upravo izostanak usklađenih interesa rezultira rezidualnim troškovima (Johannes i Lefebvre, 2025). Informacijska asimetrija je prije svega rezultat različite količine informacija o poslovanju i poslovnim odlukama kojima raspolažu vlasnici i menadžeri, koji u svakodnevnom poslovanju imaju pristup znatnoj većoj količini poslovnih informacija.

Agencijski troškovi u dosadašnjoj literaturi povezani su primarno s velikim poduzećima, međutim, Johannes i Lefebvre (2025) navode kako navedeni troškovi mogu biti identificirani i u manjim poduzećima gdje vlasnici nemaju resurse za nadzor te imaju ograničen pristup na tržište kapitala. Nadalje, pretpostavka je kako u obiteljskim poduzećima nije toliko izražen sukob interesa, no podaci ukazuju kako su agencijski troškovi jedan od značajnijih ekonomskih izazova s kojima se mala i srednja poduzeća suočavaju (Johannes i Lefebvre, 2025) uz pretpostavku odvojenosti vlasničkih i upravljačkih struktura.

Jedan od najvećih izazova vezanih uz pitanje agencijskih troškova vezan je uz način njihova izračuna. Agencijski troškovi ne mogu biti izravno izmjereni (Klačmer Čalopa i sur., 2020). Neki oblici agencijskih troškova obuhvaćeni su u financijskim izvještajima kao zasebne stavke, dok pojedini oblici ne mogu biti kvantificirani i praćeni kroz financijske izvještaje. Prema Jensen i Meckling (1976), agencijski troškovi mogu se podijeliti na tri osnovne skupine:

**Troškovi nadzora (monitoring costs)** predstavljaju troškove koje vlasnici snose kako bi pratili aktivnosti menadžera i smanjili informacijsku asimetriju. U njih se ubrajaju troškovi revizije, kontrole, rada nadzornih i revizijskih odbora te različitih oblika izvještavanja. Navedeni troškovi obuhvaćeni su financijskim izvještajima.

**Troškovi vezivanja (bonding costs)** nastaju kada menadžeri preuzimaju određene ugovorne obveze kako bi dokazali usklađenost svojih interesa s interesima vlasnika. Primjeri uključuju sustave nagrađivanja povezane s rezultatima, vlasničke udjele menadžera te različite ugovorne mehanizme odgovornosti. Navedeni troškovi obuhvaćeni su financijskim izvještajima.

**Rezidualni gubitak (residual loss)** predstavlja gubitak vrijednosti koji nastaje čak i nakon provedbe nadzora i vezivanja, kada menadžerske odluke i dalje nisu potpuno usklađene s interesima vlasnika. Takvi gubici mogu nastati zbog neoptimalnih investicijskih odluka, propuštenih poslovnih prilika ili neučinkovitog korištenja resursa. Upravo ovaj oblik agencijskih troškova predstavlja izazov u njihovom identificiranju i onemogućava kvantificiranje ukupnih agencijskih troškova.

Budući da se agencijski troškovi ne iskazuju kao zasebna stavka financijskih izvještaja kojom su obuhvaćene sve skupine, njihova se prisutnost u empirijskim istraživanjima procjenjuje putem zamjenskih varijabli, odnosno pokazatelja. Njihov izračun radi se kroz korištenje zamjenskih varijabli, poput koeficijenta obrtaja imovine (Huu Nguyen i sur., 2020), omjera operativnih troškova (Lee i Tulcanaza-Prieto, 2024) te EBITDA podijeljene s ukupnom imovinom (Johannes i Lefebvre, 2025).

## 3. AGENCIJSKI TROŠKOVI I MEHANIZMI KORPORATIVNOG UPRAVLJANJA

Literatura potvrđuje kako učinkoviti mehanizmi korporativnog upravljanja doprinose smanjenju agencijskih troškova, što se posljedično odražava na veću financijsku uspješnost poduzeća (Kyere i Ausloos, 2021; Hoang i sur., 2019). U tom kontekstu, nadzorni odbori predstavljaju ključni interni mehanizam korporativnog upravljanja, pri čemu njihova veličina, neovisnost, stručnost članova, učestalost sastanaka te postojanje i učinkovitost revizijskog odbora značajno utječe na razinu agencijskih troškova (Agarwal i Singh, 2020; Rashid i Sidra, 2021; Ain i sur., 2021; Allam, 2018). Većina

istraživanja potvrđuje da manji i neovisniji odbori, uz veću stručnost članova i učinkovit revizijski odbor, pridonose smanjenju sukoba između vlasnika i menadžera te povećavaju kvalitetu financijskog izvještavanja i transparentnost poslovanja (Agarwal i Singh, 2020; Allam, 2018; Njoku i Lee, 2025). Istodobno, praksa pokazuje da velik broj hrvatskih poduzeća još uvijek nema uspostavljen revizijski odbor (Hrvatsko društvo za korporativno upravljanje i menadžment, 2026).

Uz obilježja nadzornih odbora, značajnu ulogu imaju i karakteristike poduzeća te struktura financiranja. Dio istraživanja ukazuje kako veća poduzeća u pravilu imaju niže agencijske troškove zbog razvijenijih sustava kontrole i izvještavanja (Huu Nguyen i sur., 2020; Johannes i Lefebvre, 2025), dok su rezultati vezani uz financijsku polugu i zaduženost djelomično neujednačeni. Neka istraživanja potvrđuju da veća zaduženost može djelovati disciplinirajuće na menadžere i smanjiti agencijske troškove (Salehi i sur., 2021; Kalash, 2019), dok druga ukazuju na mogućnost njihova povećanja (Klačmer Čalopa i sur., 2020; Shaqqour, 2020). Također, istraživanja pokazuju da transparentnije izvještavanje i stroži zahtjevi objavljivanja informacija doprinose smanjenju informacijske asimetrije i agencijskih troškova (Johannes i Lefebvre, 2025; Lee i Tulcanaza-Prieto, 2024).

Dodatno, na agencijske troškove utječu i obilježja vlasničke strukture te primjena suvremenih praksi korporativnog upravljanja. Dok koncentracija vlasništva može povećati agencijske troškove, posebice u slučaju institucijskih investitora, veći vlasnički udio menadžera doprinosi usklađivanju interesa vlasnika i uprave te smanjenju navedenih troškova (Allam, 2018). Novija istraživanja također potvrđuju pozitivan doprinos ESG praksi, koje kroz veću odgovornost, transparentnost i usklađivanje interesa dionika smanjuju agencijske troškove i posredno doprinose boljoj uspješnosti poslovanja (Gregory, 2025; Xu i sur., 2025). Sumirani rezultati dosadašnjih istraživanja prikazani su Tablicom 1.

**Tablica 1. Utjecaj mehanizma korporativnog upravljanja na agencijske troškove**

| Mehanizmi korporativnog upravljanja | Utjecaj na agencijske troškove | Autori |
|---|---|---|
| Transparentnost u izvještavanju | Smanjuje | (Njoku i Lee, 2025; Lee i Tulcanaza-Prieto 2024) |
| Uspostava revizijskog odbora i njegova učinkovitost | Smanjuje | (Kyere i Ausloos, 2021; Allam, 2018) |
| Veličina nadzornog odbora | Povećava | (Agarwal i Singh, 2020; Huu Nguyen i sur., 2020; Klačmer Čalopa i sur., 2020; Fareed Shaqqour, 2020; Ain i sur., 2021) |
| Rodna heterogenost nadzornih odbora | Smanjuje | (Ain i sur., 2021) |
| Učestalost sastanaka nadzornih odbora | Povećava | (Agarwal i Singh, 2020; Fareed Shaqqour, 2020) |
| Neovisnost članova | Smanjuje | (Agarwal i Singh, 2020; Huu Nguyen i sur., 2020; Razali i sur., 2023) |
| Edukacije članova | Smanjuje | (Agarwal i Singh, 2020) |
| Financiranje dugom | Smanjuje<br>Povećava | (Huu Nguyen i sur., 2020; Mahdi Salehi i sur. 2021)<br>(Klačmer Čalopa i sur., 2020; Fareed Shaqqour 2020 |
| Visoka razina koncentracije vlasništva | Povećava | (Allam, 2018) |
| Udio menadžera u vlasništvu | Smanjuje | (Allam, 2018) |

Izvor: izrada autorica.

# 4. PRAKTIČNI ASPEKTI AGENCIJSKIH TROŠKOVA

Jedan od najvećih izazova povezanih s agencijskim troškovima proizlazi iz činjenice kako se oni ne iskazuju izravno u financijskim izvještajima. Za razliku od većine poslovnih troškova, agencijski troškovi predstavljaju posljedicu neusklađenosti interesa između vlasnika i menadžera te se najčešće manifestiraju kroz smanjenu učinkovitost poslovanja ili povećanu potrošnju resursa. Iako određeni oblici agencijskih troškova, uključujući troškove nadzora i vezivanja, prikazani su u financijskim izvještajima, oni koji se odnosi na rezidualne gubitke nisu financijski evidentirani zbog čega se radi njihova aproksimacija. Sukladno tome, vlasnici moraju koristiti kombinaciju financijskih i nefinancijskih pokazatelja kako bi identificirali moguće postojanje problema.

## 4.1. Financijski pokazatelji agencijskih troškova

Prvi signal mogućeg postojanja agencijskih troškova predstavlja kontinuirani rast operativnih troškova bez odgovarajućeg povećanja prihoda ili profitabilnosti. Takva situacija može ukazivati na povećanje menadžerske potrošnje koja ne doprinosi stvaranju vrijednosti za vlasnike. Lee i Tulcanaza-Prieto (2024) posebno ističu da povećani operativni troškovi često uključuju troškove reprezentacije, administracije, putovanja, marketinga, uredskih zgrada i druge diskrecijske izdatke kojima menadžment raspolaže. Drugi važan pokazatelj jest smanjenje koeficijenta obrtaja imovine. Koeficijent obrtaja odražava menadžersku učinkovitost, učinkovitost investicija i sposobnost menadžmenta da koristi imovinu na najproduktivniji način. Budući da navedeni pokazatelj mjeri učinkovitost korištenja imovine za generiranje prihoda, njegovo pogoršanje može upućivati na neefikasno upravljanje investicijama ili na ulaganja koja ne stvaraju očekivane ekonomske koristi (Huu Nguyen i sur., 2020; Johannes i Lefebvre, 2025). Posebnu pažnju potrebno je posvetiti projektima koji zahtijevaju značajna ulaganja kapitala, ali ostvaruju niske stope povrata. Takve investicije mogu biti posljedica menadžerske sklonosti povećanju veličine poduzeća, tržišnog utjecaja ili osobnog prestiža, iako ne doprinose povećanju vrijednosti za vlasnike. S obzirom na to da je riječ o zamjenskim varijablama za iskazivanje agencijskih troškova, važno je imati na umu kako iste imaju određena ograničenja u primjeni, s obzirom na to da se govori o aproksimaciji određene skupine agencijskih troškova, a ne o njihovu financijskom iznosu. Uz to,

financijski pokazatelji poput koeficijenta obrtaja usko su vezani za djelatnost poduzeća i fazu rasta poduzeća, dok s druge strane operativni troškovi kroz manje opsege kreativnog računovodstva mogu biti izmijenjeni u manjoj mjeri.

## 4.2. Nefinancijski pokazatelji agencijskih troškova

Osim financijskih pokazatelja, agencijski troškovi mogu se prepoznati i kroz određene organizacijske obrasce ponašanja. Jedan od njih je kontinuirani rast broja ljudi, odjela ili procesa koji se bave popratnim poslovima bez odgovarajućeg povećanja produktivnosti ili poslovnih rezultata. Takva situacija može upućivati na neučinkovitu organizacijsku strukturu. Dodatni signal predstavljaju učestale akvizicije i širenje poslovanja koje povećavaju veličinu poduzeća, ali ne rezultiraju rastom profitabilnosti. Teorija agenta pretpostavlja da menadžeri ponekad preferiraju rast organizacije jer veća poduzeća često donose veći osobni utjecaj, veće naknade i veću organizacijsku moć, čak i kada takve odluke nisu optimalne za vlasnike. Značajan pokazatelj mogu biti i sustavi nagrađivanja koji nisu povezani s dugoročnim rezultatima poslovanja. Njoku i Lee (2025) ističu da neadekvatno dizajnirani sustavi kompenzacija mogu potaknuti menadžere na ostvarivanje kratkoročnih ciljeva na štetu dugoročne održivosti i vrijednosti poduzeća. Također, vlasnici bi trebali analizirati odstupanja između financijskih i nefinancijskih pokazatelja uspješnosti. Primjerice, rast prihoda uz istodobni pad profitabilnosti, smanjenje zadovoljstva kupaca ili pogoršanje ESG pokazatelja može ukazivati na prisutnost odluka koje kratkoročno poboljšavaju određene rezultate, ali dugoročno stvaraju dodatne agencijske troškove.

## 4.3. Uloga transparentnosti u identifikaciji agencijskih troškova

Novija istraživanja naglašavaju kako transparentnost izvještavanja predstavlja jedan od najvažnijih preduvjeta za identifikaciju agencijskih troškova. Johannes i Lefebvre (2025) pokazuju da poduzeća koja posluju u okruženju sa strožim zahtjevima izvještavanja ostvaruju niže agencijske troškove zbog smanjene informacijske asimetrije između vlasnika i menadžera. Slično tome, Lee i Tulcanaza-Prieto (2024) potvrđuju da viša razina korporativne transparentnosti doprinosi učinkovitijem nadzoru

menadžmenta i smanjenju oportunističkog ponašanja. U posljednjih nekoliko godina dodatnu važnost dobiva ESG izvještavanje. Gregory (2025) te Xu i sur. (2025) utvrdili su kako kvalitetnije ESG objave povećavaju transparentnost poslovanja i smanjuju prostor za oportunističko ponašanje menadžera. Stoga ESG pokazatelji mogu predstavljati koristan dodatni izvor informacija za prepoznavanje potencijalnih agencijskih troškova.

## 4.4. Preporuke za vlasnike i nadzorne odbore

Na temelju dostupne literature može se zaključiti da identifikacija agencijskih troškova zahtijeva kontinuirano praćenje financijskih pokazatelja, usporedbu s konkurencijom te analizu organizacijskih i upravljačkih procesa, što može predstavljati okvir za uspješno provedeno korporativno upravljanje. Vlasnici i nadzorni odbori ne bi smjeli promatrati samo ostvarene financijske rezultate već i način na koji su oni ostvareni. Upravo kombinacija pokazatelja profitabilnosti, učinkovitosti korištenja imovine, transparentnosti izvještavanja, sustava nagrađivanja i kvalitete korporativnog upravljanja omogućuje pravodobno prepoznavanje agencijskih troškova i poduzimanje korektivnih mjera.

## 4.5. Hrvatski kontekst korporativnog upravljanja i agencijskih troškova

Specifičnosti hrvatskoga gospodarstva važno je uzeti u obzir prilikom analize agencijskih troškova. Hrvatsku karakterizira relativno visoka koncentracija vlasništva te značajan udio obiteljskih poduzeća, zbog čega se problemi često razlikuju od onih karakterističnih za disperzirane vlasničke strukture razvijenih tržišta kapitala. U hrvatskim poduzećima često prevladava stav da su problemi agencijskih troškova prije svega obilježje velikih poduzeća s disperziranim vlasništvom. Međutim, praksa pokazuje da ni poduzeća s koncentriranim vlasništvom, kao ni mala i srednja poduzeća, nisu imuna na probleme povezane s informacijskom asimetrijom, osobito kada vlasnici nisu aktivno uključeni u svakodnevno upravljanje. Prema podacima Board Monitora (Hrvatsko društvo za korporativno upravljanje i menadžment, 2026), broj neovisnih članova odbora i dalje je relativno ograničen, dok velik broj najvećih poduzeća u Hrvatskoj, osobito izvan skupine poduzeća koja kotiraju na burzi, nema uspostavljene revizijske odbore, dok su ostali

pododbori zastupljeni u još manjoj mjeri. Takve okolnosti mogu ograničiti učinkovitost nadzora nad menadžmentom te povećati rizik nastanka agencijskih troškova.

Istodobno, regulatorni zahtjevi povezani s održivosti i ESG izvještavanjem postupno povećavaju razinu transparentnosti poslovanja, posebno kada je riječ o nefinancijskim podacima. Navedeni trend može pozitivno utjecati na smanjenje informacijske asimetrije između vlasnika i menadžera te posljedično smanjiti agencijske troškove. Navedeno će posebno biti istaknuto u idućem razdoblju kada će se navedenom regulativom obuhvati značajan broj poduzeća, od kojih neka nisu nužno uvrštena na burzu.

## 5. KLJUČNE IMPLIKACIJE ZA KORPORATIVNO UPRAVLJANJE

Velik broj znanstvenih radova na području agencijskih troškova ukazuje kako je pitanje navedenih troškova značajno pitanje za sva poduzeća, bez obzira na veličinu, s obzirom na to da može snažno utjecati na vrijednost poduzeća. Iako je nemogućnost njihova izravnog mjerenja jedan od glavnih izazova, znanstvenici navode različite zamjenske varijable kojima se agencijski troškovi mogu indirektno izračunati poput koeficijenta obrtaja ukupne imovine, omjera operativnih troškova i prihoda te omjer EBITDA i ukupne imovinom, omogućavaju poslovnoj zajednici upravljanje navedenim troškovima.

Na temelju dosad provedenih istraživanja može se zaključiti nekoliko bitnih činjenica:

- Prva pretpostavka kod agencijskih troškova jest nužnost da poduzeća budu s istima upoznata. Uz to, njihov opseg obuhvaća veći broj različitih troškova, od kojih se neki nalaze u financijskim izvještajima, dok se drugi mogu aproksimirati putem zamjenskih varijabli. Navedeno dovodi do ograničenja u njihovu izračunu, s obzirom na to da zamjenske varijable ne omogućavaju njihovo točno kvantificiranje.
- Agencijski troškovi utječu na ukupne pokazatelje uspješnosti poslovanja poduzeća, zbog čega je važno navedenim troškovima upravljati. Odnosno, istraživanja podupiru činjenicu da postojanje agencijskih troškova doprinosi smanjenju uspješnosti poslovanja.

- Različiti mehanizmi korporativnog upravljanja, poput karakteristika nadzornih odbora mogu imati značajan utjecaj na visinu agencijskih troškova. Broj članova nadzornih odbora, nezavisnost članova i edukacija važna su pitanja koja mogu utjecati na razinu agencijskih troškova.
- Mala i srednja poduzeća koja imaju odvojene strukture vlasništva i upravljanja nisu izuzeta od pojave agencijskih troškova, štoviše, navedena problematika još je istaknutija zbog manjih financijskih resursa za uspostavu kvalitetnih mehanizama nadzora. Sukladno tome, pitanje agencijskih troškova nije isključivo vezano za velika poduzeća.
- Kvaliteta izvještavanja i visoka razina transparentnosti značajno utječe na smanjenje agencijskih troškova.
- Uvođenje revizijskog odbora i u situacijama kada nije zakonski propisano, s obzirom na to da navedeno pozitivno utječe na transparentnost izvještavanja, a time posljedično i na smanjenje agencijskih troškova.
- Rodna heterogenost nadzornih odbora može smanjiti razinu agencijskih troškova, nadovezujući se na implementaciju Direktive EU-a za rodnu ravnopravnost.
- ESG inicijative također mogu biti odličan alat za smanjenje agencijskih troškova, kroz povećanje razine transparentnosti.

# 6. ZAKLJUČAK

Iako se agencijski troškovi rijetko nalaze u fokusu vlasnika, njihovo zanemarivanje može imati značajne posljedice za uspješnost poslovanja poduzeća. Važno je imati na umu da, uz interne mehanizme korporativnog upravljanja, na agencijske troškove utječu i eksterni mehanizmi, poput zakonske regulative, ali i karakteristike poduzeća, s obzirom na to da su u poduzećima različitih veličina i s različitim stopa rasta identificirane različite visine agencijskih troškova. Upravo iz navedenog razloga, poduzeća moraju prilikom analize i praćenja agencijskih troškova biti svjesna njihovih mogućih utjecaja. Veličina poduzeća jedan je od ključnih karakteristika poduzeća koja ima učinak na razinu agencijskih troškova. Upravo i tendencija poboljšanja kvalitete korporativnog upravljanja u malim i srednjim poduzećima ide u tom smjeru, ističući važnost korporativnog upravljanja za sva poduzeća.

Najveći izazov za vlasnike nije smanjiti agencijske troškove, već ih prepoznati kako bi se moglo istima upravljati. Troškovi koji nisu u potpunosti vidljivi u financijskim izvještajima potencijalno mogu dugoročno znatno narušiti učinkovitost poslovanja i stvaranje dodane vrijednosti. Stoga pitanje agencijskih troškova ne bi trebalo promatrati kao teorijski problem korporativnog upravljanja, već kao praktično pitanje konkurentnosti poslovanja i održivosti poduzeća.

## Zahvala

Ovaj je rad financiran iz fondova Europske unije kroz NextGenerationEU instrument u okviru projekta 2025-657.

Ovaj je rad sufinancirala Hrvatska zaklada za znanost u okviru projekta [HRZZ-IP-2022-10-6703].

# LITERATURA

Agarwal, S. i Singh, A. (2020). Literature Review on the Relationship between Board Structure and Firm Performance. International Journal of Business Ethics in Developing Economies, 9 (2), 33-43.

Ain, Q. U., Yuan, X., Javaid, H. M,, Usman, M. i Haris, M. (2021). Female directors and agency costs: evidence from Chinese listed firms. International Journal of Emerging Markets, 16 (8), 1604–1633, doi: https://doi.org/10.1108/IJOEM-10-2019-0818

Allam, B. S. (2018). The impact of board characteristics and ownership identity on agency costs and firm performance: UK evidence. Corporate Governance, 18 (6), 1147–1176, doi: https://doi.org/10.1108/CG-09-2016-0184

Gregory, R. P. (2025). Do ESG Activities Reduce Agency Costs?. Dostupno na https://ssrn.com/abstract=5318619 or http://dx.doi.org/10.2139/ssrn.5318619

Hoang, L. D., Minh Tuan, T., Van Tue Nha, P. i Thu Phuong, T. (2019). Impact of agency costs on firm performance: Evidence from Vietnam, Organizations and Markets in Emerging Economies, Vilnius University Press, Vilnius, 10 (2), 294-309.

Hrvatsko društvo za korporativno upravljanje i menadžment [CCGM] (2026). Board Monitor. Dostupno na https://ccgm.hr/objavljeno-prvo-izdanje-ccgm-board-monitora/

Huu Nguyen, A., Thuy Doan, D. i Ha Nguyen, L. (2020). Corporate Governance and Agency Cost: Empirical Evidence from Vietnam. Journal of Risk and Financial Management, 13(5), 103. https://doi.org/10.3390/jrfm13050103

Johannes, P. i Lefebvre, V. (2025). Higher agency costs in smaller firms? The role of size and reporting requirements in agency conflicts. European Management Review, 22(2), 352–378. https://doi.org/10.1111/emre.12645

Kalash, I. (2019). Firm Leverage, Agency Costs and Firm Performance: An Empirical Research on Service Firms in Turkey. İnsan ve Toplum Bilimleri Araştırmaları Dergisi, 8 (1), 624-636.

Klačmer Čalopa, M., Kokotec, I. D. i Kokot, K. (2020). Impact of Board Size and Ownership Concentrationon Agency Costs: Evidence for Croatia Companies. Zbornik Radova Ekonomski Fakultet Rijeka, 38(2), 521-535.

Kyere, M. i Ausloos, M., (2021). Corporate governance and firms financial performance in the United Kingdom. Int J Fin Econ. 26, 1871–1885. https://doi.org/10.1002/ijfe.1883

Lee, Y. i Tulcanaza-Prieto, A. B. (2024). The Effect of Corporate Governance on the Degree of Agency Cost in the Korean Market. Risks, 12(4), 59. https://doi.org/10.3390/risks12040059

Salehi, M, Sadegh Adibian, M., Sadatifar, Z. i Khansalar, E. (2021). The relationship between corporate governance characteristics. Zb. rad. Ekon. fak. Rij, 39 (1), 199-220.

Jensen, M.C. i Meckling, W.H. (1976). Theory of the firm: Managerial behavior, agency costs and ownership structure, Journal of Financial Economics, 3 (4), 305-360.

Njoku, O. i Lee, Y. (2025). Agency Costs, Ownership Structure, and Cost Stickiness: Implications for Sustainable Corporate Governance. Sustainability. 17. 5144.

Fareed Shaqqour, O. (2020). Impact of Institutional Governance Tools on Reducing Agency Costs to Commercial Banks Listed in the Amman Stock Exchange. International Journal of Financial Research, 11 (5).

Rashid Khan, H. U., Khidmat, W. B., Hares, O. A., Muhammad, N. i Saleem, K. (2020). Corporate Governance Quality, Ownership Structure, Agency Costs and Firm Performance. Evidence from an Emerging Economy. Journal of Risk and Financial Management, 13(7), 154. https://doi.org/ 10.3390/jrfm13070154

Rashid Mahmood i Sidra Siddique (2021). The Impact of Corporate Governance Mechanisms and Ownership Structure on the Agency Cost with Specific Reference of Pakistan, International Journal of Management (IJM), 12(3), 976-988.

Razali, M. W. M., Nasir, N. M., Lunyai, J. i Shaharudin, S. (2023). Board Diversity and Agency Cost: Evidence from Bursa Malaysia Stock Exchange. Politeknik & Kolej Komuniti Journal of Social Sciences and Humanities, 8(1), 39–52.

Sdiq, S. R. i Abdullah, H. A. (2022). Examining the effect of agency cost on capital structure-financial performance nexus: empirical evidence for emerging market. Cogent Economics & Finance, 10(1). https://doi.org/10.1080/23322039.2022.2148364

Tipurić, D. i Cindrić, L. (2024). Nadzorni odbor: korporativno upravljanje i grupna dinamika. Zagreb: Centar za istraživanje i razvoj upravljanja d.o.o.

Tipurić, D. i sur. (2008). Korporativno upravljanje. Zagreb: Sinergija.

Xu, Y., Wang, S., Wang, T., Fan, Q. i Sham Wong, M.C. (2025). ESG Ratings, Agency Cost and Corporate Performance: The Case of Chinese Firms in 2009-2023, Sustainable Futures, 10.

# AGENCY COSTS: IDENTIFYING COSTS THAT ARE NOT FULLY REFLECTED IN FINANCIAL STATEMENTS

***Abstract***

*The core relationship observed within the framework of corporate governance is that between the manager (agent) and the owner (principal). When management and ownership structures are separated, as is especially prominent in larger companies, this leads to agency costs. The misalignment of interests between managers and owners results in agency costs that reduce the value of owners' wealth and can directly affect the company's business success. Although it is difficult to quantify overall agency costs, it is important to recognize them, and corporate governance is the primary mechanism for monitoring and potentially reducing them. Total agency costs cannot be fully presented as items in financial statements, which is why they can become significant costs that the company struggles to identify. The paper aims to provide recommendations for companies on identifying and managing agency costs through the use of various corporate governance mechanisms. The paper includes a review of theoretical and empirical literature in the field of agency costs. Furthermore, it defines the direction of influence of various corporate governance mechanisms and proxy variables used to measure agency costs. The paper contributes to practice by identifying indicators for recognizing agency costs and recommendations for their management. Although a portion of agency costs is presented in financial statements, a certain group of agency costs is not quantified. In the long term, it can impair business efficiency, which means that the issue of agency costs should not be viewed as a theoretical problem of corporate governance. Still, as a practical issue of business competitiveness and company sustainability, this is precisely the basis of the practical contribution of the aforementioned work.*

***Keywords:*** *corporate governance, corporate governance mechanisms, agency costs.*

JEL klasifikacija: L26, M13, G34, D22

Prethodno priopćenje

# SMJENA GENERACIJA KAO NEPREPOZNATI OKIDAČ RESTRUKTURIRANJA: PRIMJENA OKVIRA SEDAM KLJUČNIH ELEMENATA (7P) NA PRIJENOS POSLOVANJA U HRVATSKIM OBITELJSKIM PODUZEĆIMA

Dino Ivan Dogan*

Dina Dogan**

## SAŽETAK

Svrha rada jest preispitati dominantno tumačenje prijenosa poslovanja u obiteljskim poduzećima kao pretežno pravno-vlasničko pitanje te argumentirati da smjena generacija predstavlja predvidljiv okidač za restrukturiranje poduzeća. Metodološki, rad se temelji na kvalitativnoj sintezi domaće i međunarodne literature o sukcesiji, performansama, profesionalizaciji i digitalnoj transformaciji obiteljskih poduzeća te na konceptualnoj

* Dr. sc. Dino Ivan Dogan, izvanredni profesor, Luxembourg School of Business (e-mail: dino.dogan@luxsb.lu).

** Dr. sc. Dina Dogan, profesorica stručnog studija, Zagrebačka škola ekonomije i managementa (e-mail: dina.dogan@zsem.hr), korespondirajući autor.

primjeni okvira sedam ključnih elemenata restrukturiranja (7P: plan, ljudski potencijali (personal), procesi, podjela poslova, platforme, portfelj i performanse) na kontekst generacijske tranzicije. Okvir 7P izvorni je doprinos jednoga od autora, pa rad predstavlja njegovo eksplicitno proširenje na novo područje primjene, a ne neutralnu provjeru vanjske teorije. Sinteza pokazuje da nalazi raspršenih struja literature konvergiraju prema restrukturacijskom tumačenju sukcesije, iz čega se izvode tri provjerljive propozicije o ulozi prethodnog restrukturiranja, angažmana osnivača i zrelosti poduzeća po dimenzijama 7P u ishodu tranzicije.

**Ključne riječi:** obiteljska poduzeća, prijenos poslovanja, smjena generacija, restrukturiranje, 7P okvir.

# 1. UVOD

Obiteljska poduzeća čine okosnicu tržišnih gospodarstava: u razvijenim zapadnoeuropskim zemljama sudjeluju s više od 80 % u broju poduzeća u privatnom vlasništvu i više od 60 % u zaposlenosti (CEPOR, 2012), a u Hrvatskoj mala i srednja poduzeća, među kojima velik dio čine obiteljska, čine 99,7 % poduzeća i zapošljavaju gotovo dvije trećine svih zaposlenih (Mezulić Juric i Alpeza, 2017). Prva generacija poduzetnika iz 1990-ih danas ulazi u fazu povlačenja, čime prijenos poslovanja poprima demografsku i razvojnu dimenziju. Prema istraživanju Business Transfer Barometar 2025, čak 60 % poduzeća koja su 2015. godine imala vlasnike starije od 55 godina i danas posluju bez promjene vlasništva, uz prosječnu dob vlasnika od 72 godine; riječ je o više od 7.000 poduzeća s gotovo 60.000 zaposlenih i više od devet milijardi eura prihoda, dok je u devet godina zatvoreno oko 3.200 malih i mikropoduzeća uz gubitak više od 20.000 radnih mjesta (CEPOR, 2025). Valja napomenuti da dio navedenih pokazatelja obuhvaća širu populaciju malih i srednjih poduzeća, a ne isključivo obiteljska, pa ih u ovom radu koristimo kao naznaku razmjera problema, a ne kao precizne mjere specifične za obiteljska poduzeća. Neriješena smjena generacija time se izravno nadovezuje na teme demografskih promjena, tržišta rada i dugoročnih razvojnih potencijala hrvatskoga gospodarstva.

Postojeća literatura i praksa prijenos poslovanja pretežno promatraju kroz pravno-vlasničku i emocionalnu prizmu: tko će naslijediti udjele, kako urediti nasljednopravne odnose i kako osnivača postupno povući iz operativnog vođenja. Takav je pristup nužan, ali nedostatan: smjene vodstva u obiteljskim

poduzećima sustavno prati mjerljiv pad operativnih performansi (Bennedsen i sur., 2007), što upućuje na organizacijski diskontinuitet koji se ne može objasniti samo izborom nasljednika. Rad polazi od teze da poduzeće u trenutku povlačenja osnivača u pravilu zatječe fazu u kojoj provjereni obrasci vođenja, neformalni procesi i portfelj oblikovan u ranijem razdoblju više ne odgovaraju promijenjenim tržišnim uvjetima, zbog čega smjena generacija predstavlja predvidljiv okidač za restrukturiranje, a ne tek vlasnički događaj.

Svrha je rada trostruka. Prvo, sintezom literature o sukcesiji, performansama, profesionalizaciji i digitalnoj transformaciji pokazati da raspršeni nalazi konvergiraju prema restrukturacijskom tumačenju smjene generacija te izvesti provjerljive propozicije. Drugo, na kontekst tranzicije primijeniti okvir sedam ključnih elemenata restrukturiranja, tzv. 7P: plan, ljudski potencijali, procesi, podjela poslova, platforme, portfelj i performanse (Dogan, 2024), te pokazati da taj okvir integrira determinante uspjeha sukcesije koje literatura identificira odvojeno. Treće, iz propozicija izvesti smjernice za ekonomsku politiku podrške prijenosu poslovanja, dosad usmjerenu gotovo isključivo na transakcijsku, pravnu i financijsku dimenziju.

## 2. PREGLED LITERATURE: DETERMINANTE USPJEŠNOSTI SUKCESIJE

Prije pregleda nalaza potrebno je razgraničiti tri pojma na kojima počiva argument rada. Sukcesija se ovdje shvaća kao proces prijenosa vodstva i vlasništva s odlazeće na dolazeću generaciju, dakle šire od jednokratnoga pravnog čina prijenosa udjela (Sharma i sur., 2003; Le Breton-Miller i sur., 2004). Restrukturiranje označava namjeran i cjelovit zahvat u strategiju, strukturu, procese i portfelj kojim se poduzeće prilagođava promijenjenim uvjetima poslovanja, od reorganizacije pojedinih funkcija do temeljitoga strateškog preusmjeravanja (Dogan, 2024). Organizacijska infrastruktura skup je formaliziranih upravljačkih, procesnih i informacijskih rješenja, poput dokumentiranih procesa, izvještavanja, tijela nadzora i pravila odlučivanja, koji poduzeću omogućuju da funkcionira neovisno o pojedincu (Stewart i Hitt, 2012; Umans i sur., 2020). Determinante uspješnosti sukcesije čimbenici su za koje literatura pokazuje da mijenjaju vjerojatnost da tranzicija bude provedena i da poduzeće nakon nje zadrži razinu poslovne uspješnosti. Pregled koji slijedi organiziran je prema tim determinantama, u četiri skupine:

obiteljsko-relacijskoj, upravljačko-procesnoj, sadržajno-razvojnoj i kontekstualnoj.

Prvu skupinu čine obiteljsko-relacijske determinante. Prijenos vodstva i vlasništva najkritičniji je događaj u životnom ciklusu obiteljskog poduzeća. Model triju preklapajućih sustava – obitelji, vlasništva i poduzeća – pokazuje da sukcesija istodobno mijenja sva tri sustava (Gersick i sur., 1997), a pomak istraživačkog fokusa s izbora nasljednika prema strateškom kontinuitetu i obnovi poduzeća potvrđuje da je riječ o trajno središnjoj temi toga polja (Rovelli i sur., 2022). Ponašanje obiteljskih poduzeća u tranziciji objašnjava koncept socioemocionalnog bogatstva: vlasnici, uz financijske ciljeve, štite obiteljsku kontrolu, identitet i dinastički kontinuitet, prihvaćajući i lošije poslovne ishode ako time čuvaju obiteljski utjecaj (Gómez-Mejía i sur., 2007; Berrone, Cruz i Gómez-Mejía, 2012), zbog čega je sukcesija analitički zahtjevnija od smjene menadžmenta u neobiteljskim poduzećima (Berns i Klarner, 2017).

Drugu skupinu čine upravljačko-procesne determinante. Razlog zašto sukcesija često izostaje ili propada objašnjava se individualnim, relacijskim, kontekstualnim, financijskim i procesnim preprekama (De Massis, Chua i Chrisman, 2008), među kojima je stav prethodnika, oblikovan emocionalnom vezanošću i strahom od gubitka uloge, jedan od najsnažnijih prediktora odgađanja (De Massis i sur., 2016). Kako je planiranje dugotrajan proces razvoja nasljednika i postupnog povlačenja prethodnika (Sharma, Chrisman i Chua, 2003; Le Breton-Miller, Miller i Steier, 2004), za argument ovog rada ključan je nalaz da formalne upravljačke prakse, obiteljski ustav i profesionalizirani nadzorni odbor značajno povećavaju vjerojatnost provedbe sukcesije (Umans i sur., 2020). Organizacijska infrastruktura time prethodi uspješnoj tranziciji, pa je spremnost poduzeća, a ne samo obitelji, ključna varijabla, iako je literatura rijetko naziva restrukturiranjem.

Najizravnije dokaze da smjena nije neutralan događaj donosi studija koja, uz instrumentalnu varijablu spola prvorođenog djeteta, pokazuje da obiteljske sukcesije snižavaju operativnu profitabilnost imovine za najmanje četiri postotna boda, ponajviše u brzorastućim i kvalifikacijski zahtjevnim industrijama (Bennedsen i sur., 2007). Učinak ipak ovisi o kontekstu i mehanizmu sukcesije, pa o ishodu ne odlučuje podrijetlo nasljednika, nego usklađenost vodstva, vlasništva i organizacijskog konteksta (Minichilli i sur., 2014), što potvrđuju i pregledi koji uspjeh tranzicije povezuju s pripremljenošću organizacije i kvalitetom procesa (Berns i Klarner, 2017;

Mahto i sur., 2023). Pad performansi oko sukcesije stoga je znak organizacijskog diskontinuiteta, dakle predmet literature o restrukturiranju.

Treću skupinu čine sadržajno-razvojne determinante, one koje govore od čega se priprema sastoji. Struja najbliža restrukturacijskoj perspektivi profesionalizaciju shvaća kao formalizaciju struktura, kontrole i odlučivanja uz uključivanje neobiteljskih menadžera (Stewart i Hitt, 2012). Obiteljska poduzeća digitalizaciji pristupaju opreznije, no razvoj dinamičkih sposobnosti omogućuje im uspješnu obnovu poslovnog modela (Soluk i Kammerlander, 2021; Soluk, Miroshnychenko i sur., 2021), pri čemu krizni šokovi djeluju kao akcelerator, a obiteljska dimenzija istodobno je izvor otpornosti i kočnica (Calabrò i sur., 2021; Soluk, Kammerlander i De Massis, 2021). Nova generacija nositelj je obnove, dok identitet i komunikacijski obrasci obitelji određuju hoće li se ona dopustiti (Prügl i Spitzley, 2021). Studija šest hrvatskih obiteljskih poduzeća pokazuje da se sukcesija i digitalizacija odvijaju kao dvostruka transformacija u kojoj je angažman osnivača, od podrške preko selektivnog dopuštanja do otpora, glavni čuvar razvoja sposobnosti, snažniji i od tržišnih pritisaka (Mihotić i Pfajfar, 2026), a pregled literature o socioemocionalnom bogatstvu potvrđuje da emocionalne preferencije vodstva sustavno odgađaju i poslovno očigledna restrukturiranja (Marques i sur., 2023).

Četvrtu skupinu čine kontekstualne determinante, institucionalne i kulturne. Hrvatsku situaciju dokumentira istraživanje Business Transfer Barometar: prvo izdanje pokazalo je da više od 90 % vlasnika starijih od 55 godina pripada prvoj generaciji bez iskustva preuzimanja (Alpeza, Grubišić i Mikrut, 2015), a drugo da gotovo polovica poduzetnika nema plan prijenosa, da je očekivanje nasljeđivanja djece palo sa 73 % na 28 %, namjera prodaje porasla sa 6 % na 19 %, a udio poduzeća s osobom izvan obitelji u upravi dosegao 35 % (CEPOR, 2025). Institucionalni odgovori ostaju pretežno financijski i pravni (Mezulić Juric i Alpeza, 2017; Bloomberg Adria, 2026), premda visoka distanca moći dodatno pojačava autoritet osnivača i jaz između vlasničke i organizacijske pripremljenosti (Mihotić i Pfajfar, 2026). Sinteza tih struja pokazuje da organizacijska infrastruktura prethodi uspješnom planiranju (Umans i sur., 2020), da izostanak pripreme snizuje rezultate (Bennedsen i sur., 2007; Minichilli i sur., 2014), da sadržaj pripreme čine profesionalizacija i digitalizacija (Stewart i Hitt, 2012; Soluk i Kammerlander, 2021), dakle elementi koje okvir 7P sistematizira (Dogan, 2024), te da je angažman osnivača ključan moderator njihove provedivosti (Mihotić i Pfajfar, 2026). Iz prvoga nalaza, o pripremljenosti poduzeća kao

prediktoru odvojenom od formalnoga plana, izvodi se propozicija P1; iz nalaza o angažmanu osnivača kao moderatoru provedivosti, propozicija P2; iz nalaza da o veličini pada performansi odlučuje organizacijska usklađenost, propozicija P3. Budući da nijedna struja te nalaze ne objedinjuje u provediv dijagnostički instrument, propozicije u konceptualnom radu imaju ulogu hipoteza za buduću empirijsku provjeru:

**P1:** Vjerojatnost uspješnog prijenosa poslovanja raste sa stupnjem prethodno provedenog strateško-organizacijskog restrukturiranja poduzeća (formalizacija procesa, profesionalizacija upravljanja, modernizacija platformi), neovisno o postojanju formalnog plana sukcesije.

**P2:** Angažman osnivača moderira odnos između restrukturacijskih aktivnosti i ishoda tranzicije: uz aktivnu podršku osnivača restrukturiranje se provodi prije ili tijekom smjene i ublažava pad performansi, dok se uz otpor osnivača izostavlja ili odgađa do postsukcesijske krize.

**P3:** Poduzeća s višim stupnjem zrelosti prema dimenzijama okvira 7P u trenutku smjene generacije ostvaruju manji postsukcesijski pad operativnih performansi od poduzeća s nižim stupnjem zrelosti.

## 3. SMJENA GENERACIJA KAO OKIDAČ RESTRUKTURIRANJA

Nasljednik ne preuzima poduzeće u neutralnom stanju, nego poduzeće čiji su procesi, platforme i portfelj oblikovani u ranijem razdoblju i prilagođeni tržištu koje u međuvremenu više nije isto. Upravo zato smjena generacija djeluje kao okidač restrukturiranja u smislu definiranom u prethodnom poglavlju, od jednostavne reorganizacije do temeljitoga strateškog i organizacijskog preusmjeravanja (Dogan, 2024). Da je ta potreba sustavna, a ne slučajna, pokazuje način na koji nastaju poslovne poteškoće: poduzeća put od prosperiteta do neuspjeha ne prelaze u jednom koraku, nego kroz niz faza; od predfaze preko rane faze i međufaze do završne faze, koje odgovornima ostavljaju vrijeme za djelovanje (DiNapoli, Sigoloff i Cushman, 1991, prema Dogan, 2024). U predfazi poslovanje teče dobro, prihodi i dobit ne daju povoda za zabrinutost, a menadžment se navikava na prividno održiv uspjeh; upravo je ta faza često začetnik kasnije razvijene krize, a poduzeća s dugom poviješću uspjeha, čije vodstvo čine iskusni „kapetani po lijepom vremenu“, posebno su izložena opasnosti da nadolazeće promjene prepoznaju prekasno.

Ta se dinamika izravno preslikava na obiteljska poduzeća u trenutku smjene generacija. Osnivač koji je poduzeće izgradio i desetljećima uspješno vodio prirodno se oslanja na provjerena načela, no prošli i sadašnji uspjeh nisu jamstvo budućega; predugo raditi nešto dobro postaje problem kada ponuda više ne odgovara zahtjevima tržišta (Dogan, 2024). Budući da nasljednik preuzima poduzeće čiji su procesi, platforme i portfelj oblikovani u ranijem razdoblju, postoji sustavan razlog da se dio poduzeća u trenutku smjene nalazi u predfazi ili ranoj fazi krize, iako pregledana literatura ne mjeri izravno u kojem se udjelu slučajeva to doista događa. Uz tu ogradu, empirijski dokumentiran pad operativne profitabilnosti oko smjene vodstva (Bennedsen i sur., 2007) barem se dijelom može tumačiti kao cijena propuštenog restrukturiranja, a ne isključivo kao neizbježna posljedica promjene osobe na čelu. Koliki udio taj mehanizam objašnjava u odnosu na druge, poput gubitka specifičnog ljudskog kapitala nasljednika ili tržišnih šokova, otvoreno je empirijsko pitanje koje propozicija P3 čini provjerljivim.

Iz toga proizlazi središnja teza rada: smjena generacija nije samo vlasnički i nasljednopravni događaj nego i predvidljiv okidač restrukturiranja, a trenutak povlačenja osnivača rijetka je prilika za temeljito preispitivanje strategije, strukture, procesa i portfelja prije nego što izostanak prilagodbe preraste u otvorenu krizu. U praksi se upravo tako odvijaju uspješni prijenosi: u jednom od rijetkih javno dokumentiranih hrvatskih primjera uspješne tranzicije s obiteljskog na profesionalno vođenje kao ključni čimbenici navode se digitalizacija poslovnih procesa, uspostava sustava izvještavanja i pravodobna priprema svih sudionika, uz razdoblje prilagodbe od dvije do tri godine (Bloomberg Adria, 2026). Ti čimbenici nisu nasljednopravne, nego izrazito restrukturacijske naravi, čime se otvara pitanje kojim se okvirom taj proces može sustavno voditi.

## 4. OKVIR SEDAM KLJUČNIH ELEMENATA (7P) PRIMIJENJEN NA SMJENU GENERACIJA

Okvir sedam ključnih elemenata uspješnog restrukturiranja obuhvaća plan, ljudske potencijale, procese, podjelu poslova, platforme, portfelj i performanse (Dogan, 2024). Kratica 7P potječe od engleskih naziva elemenata (plan, personnel, processes, partition, platforms, portfolio, performance) i u ovome se radu preuzima kao ustaljeno ime okvira (Dogan, 2024), a ne kao mnemotehnika hrvatskoga nazivlja, slično kao što se u

hrvatskoj literaturi zadržava kratica 4P marketinškoga spleta. Šest od sedam hrvatskih naziva ionako počinje istim slovom; iznimka je element ljudskih potencijala, za koji hrvatski nema ustaljen istovrijednik na p. Za razliku od normativnih kontrolnih lista, okvir polazi od pretpostavke da je svako poduzeće jedinstveno te da se elementi oblikuju situacijski, pri čemu upravo njihova cjelovitost čini pretpostavku uspjeha. Ta ga svojstva razlikuju od dominantnih modela sukcesije: model triju krugova objašnjava dinamiku odnosa obitelji, vlasništva i poduzeća (Gersick i sur., 1997), fazni modeli opisuju vremenski slijed razvoja nasljednika i povlačenje prethodnika (Le Breton-Miller i sur., 2004), a istraživanja determinanti identificiraju pojedinačne čimbenike tranzicije (De Massis i sur., 2008; Umans i sur., 2020). Nijedan od tih pristupa ne odgovara na pitanje koje se postavlja nakon donošenja odluke o tranziciji: koje organizacijske zahvate poduzeće mora provesti da bi smjenu preživjelo bez pada performansi dokumentiranog u literaturi (Bennedsen i sur., 2007). Okvir 7P stoga se ne predlaže kao zamjena za modele sukcesije, nego kao njihova provedbena nadopuna: modeli sukcesije objašnjavaju tko, kada i zašto, a okvir 7P operacionalizira što i kako.

## 4.1. Plan

Plan definira početnu poziciju poduzeća, ciljanu poziciju nakon promjene te put i troškove njihova premošćivanja (Dogan, 2024). U kontekstu sukcesije taj element zahtijeva zaokret u redoslijedu pitanja: umjesto da tranzicija započne pitanjem tko preuzima vlasništvo, treba započeti pitanjem kakvo poduzeće nasljednik preuzima i kamo ono treba stići. Literatura taj zaokret posredno podupire: planiranje sukcesije jest planirano ponašanje čija provedba ovisi o strukturiranom procesu, a ne o dobrim namjerama (Sharma i sur., 2003), dok stav prethodnika određuje hoće li planiranje uopće započeti (De Massis i sur., 2016). Podatak da samo 7 % hrvatskih poduzetnika ima pisani plan prijenosa (CEPOR, 2025) upućuje na to da u praksi izostaje već prvi element okvira, čime svi ostali gube uporište. Iz restrukturacijske perspektive dodatno je važna provjera motivacije naručitelja: deklarativna spremnost osnivača na povlačenje bez stvarne spremnosti na predaju kontrole predstavlja latentan rizik koji plan mora eksplicitno adresirati (Dogan, 2024).

## 4.2. Ljudski potencijali (personal)

Element ljudskih potencijala polazi od načela da promjene ne provode organizacije, nego ljudi te da se ključne pozicije popunjavaju pozitivnom selekcijom prema kriterijima obrazovanja, iskustva, dokazivih rezultata i osobne primjerenosti (Dogan, 2024). Taj element ima najizravniju empirijsku potvrdu: podbačaj obiteljskih nasljednika najizraženiji je u industrijama koje zahtijevaju visokokvalificiranu radnu snagu, dok profesionalni neobiteljski menadžeri pružaju mjerljivo vrijedne usluge poduzećima kojima upravljaju (Bennedsen i sur., 2007), pri čemu ishod ne određuje podrijetlo nasljednika samo po sebi, nego usklađenost vodstva s vlasničkim i organizacijskim kontekstom (Minichilli i sur., 2014). Profesionalizacija se ne iscrpljuje zapošljavanjem vanjskog direktora, nego obuhvaća i formalizaciju sustava odlučivanja i kontrole (Stewart i Hitt, 2012). Izbor između obiteljskog i neobiteljskog nasljednika stoga nije pitanje lojalnosti, nego selekcijski problem: organizacija se gradi oko zadataka, a za članove obitelji čije kompetencije ne odgovaraju potrebama mogu se oblikovati funkcije koje čuvaju ugled bez narušavanja učinkovitosti (Dogan, 2024). Uključenost osoba izvan obitelji u upravljanje u 35 % hrvatskih poduzeća (CEPOR, 2025) pokazuje da se praksa u tom smjeru već razvija.

## 4.3. Procesi

Procesni element zahtijeva analizu poslovnih procesa s obzirom na efektivnost i efikasnost te njihovo dokumentiranje i redizajn (Dogan, 2024). U poduzećima prve generacije procesi su obično neformalni i personalizirani, vezani uz osnivača kao središnju točku odlučivanja, što je izvor fleksibilnosti, ali i strukturne ranjivosti (Stewart i Hitt, 2012). U trenutku sukcesije ta ranjivost postaje akutna: odlaskom osnivača poduzeće ne gubi samo vođu, nego i nedokumentirano procesno znanje, čime se objašnjava dio postsukcesijskog pada performansi. Budući da formalne upravljačke prakse empirijski povećavaju vjerojatnost planiranja sukcesije (Umans i sur., 2020), formalizacija procesa istodobno je pretpostavka i sadržaj uspješne tranzicije: zahvati poput redovitih sastanaka s dokumentiranim odlukama, jasnih odgovornosti i sustavnog izvještavanja pretvaraju prešutno znanje osnivača u organizacijsko znanje te nasljedniku omogućuju upravljanje poduzećem koje više ne ovisi o jednoj osobi (Dogan, 2024).

## 4.4. Podjela poslova

Element podjele poslova počiva na načelu da struktura slijedi strategiju te da se organizacijske jedinice dimenzioniraju prema poslovnim potrebama, a ne prema zatečenim osobama (Dogan, 2024). U obiteljskim poduzećima taj je element osobito osjetljiv jer se pozicije nerijetko dodjeljuju prema pripadnosti obitelji – obrazac koji koncept socioemocionalnog bogatstva objašnjava težnjom očuvanja kontrole i dinastičkog kontinuiteta čak i kada to nosi poslovne troškove (Gómez-Mejía i sur., 2007; Berrone i sur., 2012). Sukcesija je prirodan trenutak za prekid toga obrasca jer se struktura ionako mora redefinirati, a restrukturacijska perspektiva nudi pragmatičan instrument za najosjetljiviji dio zadatka: razgraničenje stvarnog doprinosa od formalnog položaja te prijelazna rješenja koja omogućuju povlačenje bez gubitka obraza (Dogan, 2024). Time se izravno adresiraju relacijske prepreke, sukobi i rivalstva među članovima obitelji, koje literatura ubraja među najčešće uzroke propalih tranzicija (De Massis i sur., 2008).

## 4.5. Platforme

Platforme obuhvaćaju informacijsko-tehnološku, komunikacijsku i suradničku infrastrukturu poduzeća (Dogan, 2024). Recentna literatura na ovom elementu najjasnije pokazuje generacijsku dimenziju restrukturiranja: nova generacija sustavno se pojavljuje kao nositelj digitalne obnove, dok identitet i komunikacijski obrasci obitelji određuju hoće li se ta obnova dopustiti (Soluk i Kammerlander, 2021; Prügl i Spitzley, 2021). Studija hrvatskih obiteljskih poduzeća pokazuje da se sukcesija i digitalizacija odvijaju kao dvostruka transformacija u kojoj angažman osnivača djeluje kao glavni čuvar razvoja sposobnosti, snažniji i od tržišnih pritisaka (Mihotić i Pfajfar, 2026). Iz perspektive okvira 7P to znači da modernizacija platformi nije tehnički detalj tranzicije, nego njezino strateško težište te da uspjeh toga elementa presudno ovisi o elementu plana, o stvarnoj motivaciji osnivača da promjenu dopusti. Komunikacijska dimenzija ima i zaštitnu funkciju: sustavno informiranje zaposlenika tijekom emocionalno zahtjevne tranzicije sprječava glasine i odljev ključnih ljudi, po istoj logici po kojoj komunikacija štiti restrukturiranja u kriznim uvjetima (Dogan, 2024).

## 4.6. Portfelj

Element portfelja polazi od spoznaje da prošli i sadašnji uspjeh nisu jamstvo budućega te da zastarjela ponuda nerijetko predstavlja dubinski uzrok poteškoća poduzeća (Dogan, 2024). U sukcesijskom kontekstu taj element ima posebnu težinu jer je portfelj prve generacije u pravilu izraz osnivačeve izvorne poduzetničke ideje, pa njegova revizija nosi emocionalni teret koji nadilazi poslovnu računicu, mehanizam koji literatura o socioemocionalnom bogatstvu dokumentira kao sustavan izvor otpora strateškim promjenama (Gómez-Mejía i sur., 2007; Marques i sur., 2023). Istodobno, prilagodbeni kapacitet, uključujući spremnost na reviziju ponude i poslovnoga modela, razlikuje otporna obiteljska poduzeća od ranjivih (Calabrò i sur., 2021; Soluk, Kammerlander i De Massis, 2021). Sukcesija je stoga prirodan trenutak za sustavnu analizu profitabilnosti i tržišne održivosti portfelja, uz strateške smjerove poboljšanja, racionalizacije i inovacije: restrukturiranje ne znači da se mora promijeniti sve, nego da se dobra rješenja zadržavaju, a promjene usmjeravaju onamo gdje ih zahtijeva održivost (Dogan, 2024).

## 4.7. Performanse

Posljednji element zahtijeva da se napredak promjene i poslovni rezultati objektivno i kontinuirano mjere kroz stratešku, operativnu i transformacijsku dimenziju (Dogan, 2024). U sukcesijskom kontekstu taj element ima trostruku funkciju. Dijagnostički, mjerenje uspostavljeno prije tranzicije omogućuje razlikovanje pada performansi uzrokovanog smjenom od pada uzrokovanog tržišnim kretanjima (Bennedsen i sur., 2007). Upravljački, sustav pokazatelja novom vodstvu daje instrument ranog prepoznavanja odstupanja u razdoblju najveće ranjivosti poduzeća. Legitimacijski, prelazak s upravljanja utemeljenog na intuiciji osnivača na upravljanje utemeljeno na podacima označava dovršetak profesionalizacije te nasljedniku daje objektivnu osnovu autoriteta koju ne može izvesti iz osnivačke karizme (Stewart i Hitt, 2012).

## 4.8. Integracija: mapiranje determinanti sukcesije na elemente okvira

Analiza pojedinačnih elemenata omogućuje da se determinante uspješnosti sukcesije, grupirane u drugom poglavlju, izraze kao zahtjevi prema pojedinim elementima okvira. Tablica 1. sažima to mapiranje.

**Tablica 1. Mapiranje determinanti uspjeha sukcesije iz literature na elemente okvira 7P**

| Element 7P | Determinanta iz literature o sukcesiji (skupina) | Ključni izvori |
|---|---|---|
| Plan | Postojanje i provedba plana sukcesije; stav prethodnika prema tranziciji (1. i 2. skupina) | Sharma i sur. (2003); De Massis i sur. (2016) |
| Ljudski potencijali (personal) | Sposobnost i priprema nasljednika; profesionalizacija menadžmenta (2. i 3. skupina) | Le Breton-Miller i sur. (2004); Bennedsen i sur. (2007); Stewart i Hitt (2012) |
| Procesi | Formalne upravljačke prakse; prijenos znanja (2. skupina) | Umans i sur. (2020); Stewart i Hitt (2012) |
| Podjela poslova | Relacijske prepreke; razdvajanje obiteljskih i poslovnih uloga (1. skupina) | De Massis i sur. (2008); Gersick i sur. (1997) |
| Platforme | Digitalna transformacija; međugeneracijska dinamika moći (3. skupina) | Soluk i Kammerlander (2021); Prügl i Spitzley (2021); Mihotić i Pfajfar (2026) |
| Portfelj | Strateška obnova: otpor promjenama zbog socioemocionalnog bogatstva (1. i 3. skupina) | Gómez-Mejía i sur. (2007); Calabrò i sur. (2021); Marques i sur. (2023) |
| Performanse | Postsukcesijske performanse; kontekstualna usklađenost vodstva (2. i 4. skupina) | Bennedsen i sur. (2007); Minichilli i sur. (2014) |

Izvor: izrada autora.

Mapiranje pruža tri konkretna uvida. Prvo, determinante koje literatura iznosi kao preporuke, formalne upravljačke prakse i prijenos znanja (Umans i sur., 2020; Stewart i Hitt, 2012), u okviru postaju zadaci elementa procesa s provjerljivim rezultatom: dokumentirane odluke, jasne odgovornosti i uspostavljeno izvještavanje. Drugo, relacijske prepreke i preklapanje obiteljskih i poslovnih uloga (De Massis i sur., 2008; Gersick i sur., 1997)

pripadaju elementu podjele poslova, dakle rješavaju se strukturnim, a ne isključivo međuljudskim instrumentom, što je operativno bitna razlika. Treće, elementi nisu neovisni: nalaz da angažman osnivača djeluje kao čuvar razvoja sposobnosti (Mihotić i Pfajfar, 2026) upućuje na to da element plana, posredstvom motivacije naručitelja, uvjetuje provedivost svih ostalih, što je sadržaj propozicije P2. Okvir time nudi i hijerarhiju: bez razriješene motivacije osnivača ulaganje u ostale elemente ostaje bez učinka, dok cjelovit zahvat na svih sedam elemenata, a ne parcijalna intervencija, razlikuje uspješne tranzicije od neuspješnih, što je sadržaj propozicije P1. Mapiranje je pritom autorska konstrukcija, pa ne dokazuje potpunost okvira, nego pokazuje da je dovoljno širok da obuhvati postojeće nalaze; provjeru omogućuje tek neovisna empirijska primjena, što je sadržaj propozicije P3.

## 5. IMPLIKACIJE ZA EKONOMSKU POLITIKU

Rasprava o ekonomskoj politici Hrvatske u pravilu se vodi oko demografskih kretanja, tržišta rada i dugoročnih razvojnih potencijala, no starenje vlasničke strukture poduzeća pripada u isti krug pitanja: demografska tranzicija ne zahvaća samo radnu snagu i mirovinski sustav nego i kapital, znanje i tržišne odnose akumulirane u više od 7.000 poduzeća čiji se osnivači, prosječne dobi od 72 godine, povlače (CEPOR, 2025). Ako je pad performansi oko sukcesije posljedica organizacijskog diskontinuiteta, a ne slučajnosti izbora nasljednika (Bennedsen i sur., 2007; Minichilli i sur., 2014), onda neuspjele tranzicije predstavljaju sustavni gubitak produktivnosti, čime se prijenos poslovanja veže uz agendu konkurentnosti gospodarstva, a ne samo uz politiku malih i srednjih poduzeća. Postojeći instrument, međutim, usmjeren je gotovo isključivo na transakcijsku dimenziju: vaučeri za prijenos vlasništva, uvedeni 2024. s ukupno 0,7 milijuna eura do 2028., sufinanciraju savjetodavne usluge u samom činu prijenosa (Bloomberg Adria, 2026), uz pretpostavku da je poduzeće koje se prenosi u osnovi zdravo. Nalazi ovoga rada tu pretpostavku dovode u pitanje: ako poduzeće u trenutku smjene tipično zateče predfazu krize, takve mjere rješavaju simptom, a ne uzrok, a nerazmjer od 0,7 milijuna eura potpore nasuprot devet milijardi eura prihoda u ugroženoj populaciji znači da politika mora birati gdje će ograničena sredstva proizvesti najveći učinak.

Za taj alokacijski problem propozicije rada nude kriterije. Iz P1 slijedi pomak težišta podrške s transakcije na pripremu: savjetodavne usluge uz pravne i porezne aspekte trebale bi obuhvatiti organizacijsku dijagnostiku i plan

restrukturiranja prije prijenosa, po uzoru na slovenski model sufinanciranja 60 % savjetodavnih usluga poduzetnicima koji odlaze u mirovinu (CEPOR, 2022). Iz P2 slijedi da politika mora doprijeti do osnivača prije nego što tranzicija postane neizbježna jer financijski instrumenti ne mogu pokrenuti proces koji osnivač ne želi (Mihotić i Pfajfar, 2026); uputno je nizozemsko iskustvo proaktivnoga poštanskog informiranja vlasnika starijih od 55 godina s pozivom na besplatno savjetovanje (CEPOR, 2022), intervencija koja je jeftina, a usmjerena na varijablu koja uvjetuje sve ostale. Iz P3 slijedi da dijagnostika zrelosti po sedam dimenzija, kao prvi korak korištenja potpore, može razlikovati poduzeća kojima je dovoljna transakcijska podrška od onih kojima je prije prijenosa potrebno restrukturiranje te istodobno generirati podatke za evaluaciju mjera.

Prema tim smjernicama valja zadržati oprez: propozicije još nisu empirijski provjerene na hrvatskim podacima, a međunarodna iskustva dolaze iz razvijenijih ekosustava podrške, pa ih valja tretirati kao hipoteze za pilot-program s ugrađenom evaluacijom. Te granice, međutim, ne mijenjaju osnovnu poruku: trošak neaktivnosti, vidljiv u dosadašnjih više od 20.000 izgubljenih radnih mjesta, nije zanemariv i valja ga usporediti s troškom pilot-programa kojim bi se restrukturacijska dimenzija uvela u politiku podrške prijenosu poslovanja.

## 6. ZAKLJUČNA RAZMATRANJA

Rad temeljno polazi od jaza u dominantnom tumačenju prijenosa poslovanja: literatura o sukcesiji temeljito je obradila pitanja tko, kada i zašto, ali znatno manje pitanje s kojim poduzećem nasljednik ulazi u tržišnu utakmicu, iako nalazi o padu operativne profitabilnosti oko smjene vodstva (Bennedsen i sur., 2007; Minichilli i sur., 2014) upućuju na to da o ishodu presudno odlučuje organizacijska, a ne samo obiteljska spremnost. Slijedom toga, rad teorijski povezuje dvije dosad odvojene rasprave, o prijenosu poslovanja i o restrukturiranju, te kroz tri propozicije i sustavno mapiranje determinanti pokazuje da okvir 7P integrira činitelje uspjeha sukcesije koje literatura identificira raspršeno, nadopunjujući modele sukcesije provedbenom dimenzijom: oni objašnjavaju tko, kada i zašto, a okvir 7P operacionalizira što i kako. Praktično vlasnicima i nasljednicima nudi dijagnostički instrument s jasnom hijerarhijom, u kojoj razriješena motivacija osnivača uvjetuje provedivost svih ostalih elemenata. Za ekonomsku politiku pokazuje da instrument usmjeren isključivo na transakciju rješava simptom, a ne uzrok, te

nudi kriterij za usmjeravanje ograničenih javnih sredstava prema poduzećima kojima je priprema najpotrebnija.

Rad je konceptualno-pregledan; dio pokazatelja odnosi se na šira mala i srednja poduzeća, a ne isključivo na obiteljska, a međunarodna iskustva prenesena su iz konteksta s razvijenijim ekosustavima podrške, pa i predložene smjernice valja tretirati kao hipoteze za pilot-programe s ugrađenom evaluacijom. Dodatno ograničenje jest što okvir 7P čini izvorni doprinos koautora, zbog čega njegovu integrativnu snagu treba potvrditi neovisnom empirijskom provjerom. Upravo zato propozicije ujedno čine program budućih istraživanja: P1 je provjerljiva longitudinalnim praćenjem poduzeća iz populacije Business Transfer Barometra, P2 poziva na kvantitativnu provjeru moderacijskog učinka angažmana osnivača na većim uzorcima, nadovezujući se na kvalitativne nalaze Mihotić i Pfajfara (2026), a P3 zahtijeva operacionalizaciju zrelosti po dimenzijama 7P u mjerni instrument, čime bi okvir prerastao u empirijski provjerljiv konstrukt. S obzirom na dob vlasničke strukture dokumentiranu u hrvatskim podacima, takva su istraživanja i praktično hitna.

## LITERATURA

Alpeza, M., Grubišić, N. i Mikrut, M. (2015). *Business Transfer Barometar Hrvatska*. Zagreb: CEPOR.

Bennedsen, M., Nielsen, K. M., Pérez-González, F. i Wolfenzon, D. (2007). Inside the family firm: The role of families in succession decisions and performance. *Quarterly Journal of Economics, 122*(2), 647-691.

Berns, K. V. i Klarner, P. (2017). A review of the CEO succession literature and a future research program. *Academy of Management Perspectives, 31*(2), 83-108.

Berrone, P., Cruz, C. i Gómez-Mejía, L. R. (2012). Socioemotional wealth in family firms: Theoretical dimensions, assessment approaches, and agenda for future research. *Family Business Review, 25*(3), 258-279.

Bloomberg Adria (2026). Tiha generacijska smjena: Što prisiljava vlasnike u regiji na prodaju poduzeća? Dostupno na https://hr.bloombergadria.com/businessweek-adria/pod-lupom/100525/sto-prisiljava-vlasnike-u-regiji-da-prodaju-svoja-poduzeca/news [15.5.2026.]

Calabrò, A., Frank, H., Minichilli, A. i Suess-Reyes, J. (2021). Business families in times of crises: The backbone of family firm resilience and continuity. *Journal of Family Business Strategy, 12*(2), 100442.

CEPOR (2012). *Razvoj i održivost obiteljskih poduzeća u Hrvatskoj.* Zagreb: CEPOR.

CEPOR (2022). Podrška poduzetnicima kod prijenosa poslovanja. Dostupno na https://www.obiteljsketvrtke.hr/tekstovi/podrska-poduzetnicima-kod-prijenosa-poslovanja [17.5.2026.]

CEPOR (2025). *Business Transfer Barometar 2025.* Zagreb: CEPOR.

De Massis, A., Chua, J. H. i Chrisman, J. J. (2008). Factors preventing intra-family succession. *Family Business Review, 21*(2), 183-199.

De Massis, A., Sieger, P., Chua, J. H. i Vismara, S. (2016). Incumbents' attitude toward intra-family succession: An investigation of its antecedents. *Family Business Review, 29*(3), 278-300.

DiNapoli, D., Sigoloff, S. C. i Cushman, R. F. (1991). *Workouts and Turnarounds: The Handbook of Restructuring and Investing in Distressed Companies.* New York: Irwin Professional Publishing.

Dogan, D. (2024). *Seven Building Blocks of a Successful Corporate Restructuring*. Wiesbaden: Springer.

Gersick, K. E., Davis, J. A., Hampton, M. M. i Lansberg, I. (1997). *Generation to Generation: Life Cycles of the Family Business.* Boston: Harvard Business School Press.

Gómez-Mejía, L. R., Haynes, K. T., Núñez-Nickel, M., Jacobson, K. J. L. i Moyano-Fuentes, J. (2007). Socioemotional wealth and business risks in family-controlled firms: Evidence from Spanish olive oil mills. *Administrative Science Quarterly, 52*(1), 106-137.

Le Breton-Miller, I., Miller, D. i Steier, L. P. (2004). Toward an integrative model of effective FOB succession. *Entrepreneurship Theory and Practice, 28*(4), 305-328.

Mahto, R. V., Cavazos, D. E., Calabrò, A. i Vanevenhoven, J. P. (2023). CEO succession game in family firms: Owners vs. advisors. *Journal of Small Business Management*, 61(6), 2714-2731.

Marques, I. C. P., Leitão, J., Ferreira, J. i Cavalcanti, A. (2023). The socioemotional wealth of leaders in family firm succession and corporate governance processes: A systematic literature review. *International Journal of Entrepreneurial Behavior & Research, 29*(1), 268-295.

Mezulić Juric, P. i Alpeza, M. (2017). *Izazovi prijenosa poslovanja u malim i srednjim poduzećima.* Zagreb: CEPOR.

Mihotić, L. i Pfajfar, G. (2026). Dynamic capabilities at the digital-succession nexus: How family firms navigate dual transformation through three developmental pathways. *Technovation*, *152*, 103484.

Minichilli, A., Nordqvist, M., Corbetta, G. i Amore, M. D. (2014). CEO succession mechanisms, organizational context, and performance: A socio-emotional wealth perspective on family-controlled firms. *Journal of Management Studies*, *51*(7), 1153-1179.

Prügl, R. i Spitzley, D. I. (2021). Responding to digital transformation by external corporate venturing: an enterprising family identity and communication patterns perspective. *Journal of Management Studies*, *58*(1), 135-164.

Rovelli, P., Ferasso, M., De Massis, A. i Kraus, S. (2022). Thirty years of research in family business journals: Status quo and future directions. *Journal of Family Business Strategy, 13*(3), 100422.

Sharma, P., Chrisman, J. J. i Chua, J. H. (2003). Succession planning as planned behavior: Some empirical results. *Family Business Review, 16*(1), 1-15.

Soluk, J. i Kammerlander, N. (2021). Digital transformation in family-owned Mittelstand firms: A dynamic capabilities perspective. *European Journal of Information Systems, 30*(6), 676-711.

Soluk, J., Kammerlander, N. i De Massis, A. (2021). Exogenous shocks and the adaptive capacity of family firms: Exploring behavioral changes and digital technologies in the COVID-19 pandemic. *R&D Management, 51*(4), 364-380.

Soluk, J., Miroshnychenko, I., Kammerlander, N. i De Massis, A. (2021). Family influence and digital business model innovation: The enabling role of dynamic capabilities. *Entrepreneurship Theory and Practice, 45*(4), 867-905.

Stewart, A. i Hitt, M. A. (2012). Why can't a family business be more like a nonfamily business? Modes of professionalization in family firms. *Family Business Review, 25*(1), 58-86.

Umans, I., Lybaert, N., Steijvers, T. i Voordeckers, W. (2020). Succession planning in family firms: Family governance practices, board of directors, and emotions. *Small Business Economics, 54*(1), 189-207.

# GENERATIONAL SUCCESSION AS AN UNRECOGNISED TRIGGER OF RESTRUCTURING: APPLYING THE SEVEN KEY ELEMENTS (7P) FRAMEWORK TO BUSINESS TRANSFER IN CROATIAN FAMILY FIRMS

***Abstract***

*The purpose of this paper is to reconsider the prevailing interpretation of business transfer in family firms as a predominantly legal and ownership-related matter, and to argue that generational succession represents a predictable trigger of corporate restructuring. Methodologically, the paper builds on a qualitative synthesis of domestic and international literature on succession, performance, professionalisation and digital transformation of family firms, and on a conceptual application of the seven key elements of restructuring framework (7P: plan, personnel, processes, partition, platforms, portfolio and performance) to generational transition. As the 7P framework is an original contribution of one of the authors, the paper constitutes an explicit extension of that framework to a new field of application rather than a neutral test of an external theory. The synthesis shows that dispersed streams of literature converge towards a restructuring interpretation of succession, from which three testable propositions are derived concerning the role of prior restructuring, founder engagement and firm maturity across the 7P dimensions in transition outcomes.*

***Keywords:*** *family firms, business transfer, generational succession, restructuring, 7P framework.*

JEL klasifikacija: G34, K22, M10, O33.

Prethodno priopćenje

# O ČEMU RASPRAVLJAMO? SUPSTITUCIJA PROSUDBE, PARADIGMA ODNOSA I NADZORNI KAPACITET KAO TRI SREDIŠNJE OSI RASPRAVE O ODNOSU ODBORA I UMJETNE INTELIGENCIJE

Elena Perić*

Domagoj Hruška**

## SAŽETAK

Rad predstavlja kritički narativni pregled i sistematizaciju suprotstavljenih teorijskih, empirijskih i normativnih stajališta u znanstvenoj literaturi o odnosu odbora i umjetne inteligencije. Polazi od istraživačkih pitanja: koja suprotstavljena stajališta postoje u literaturi te oko kojih se osi rasprave vode i na kojim teorijskim tradicijama počivaju. Metodološki se temelji na kvalitativnoj konceptualnoj sintezi i teorijskoj analizi relevantne znanstvene i stručne literature s područja korporativnog upravljanja, korporativnog prava

* Elena Perić, univ. mag. oec., Sveučilište u Zagrebu, Ekonomski fakultet, Katedra za organizaciju i menadžment (e-mail: eperic1@efzg.hr), korespondirajući autor.

** Prof. dr. sc. Domagoj Hruška, Sveučilište u Zagrebu, Ekonomski fakultet, Katedra za organizaciju i menadžment (e-mail: dhruska@efzg.hr).

i umjetne inteligencije. Sistematizirane su tri međusobno uvjetovane rasprave: o supstituciji ljudske prosudbe (optimizacija odlučivanja nasuprot nedelegabilnosti fiducijarnih dužnosti pažnje i lojalnosti), o konceptualizaciji odnosa (umjetna inteligencija kao resurs odbora nasuprot objektu nadzora i rizika) te o nadzornom kapacitetu odbora u uvjetima visoke tehnološke složenosti. Iz hijerarhije tih rasprava izvode se dva scenarija budućnosti korporativnog upravljanja. Prvi je patološki, u kojem niska digitalna pismenost i algoritamsko zarobljavanje svode nadzorni odbor na „ljudski pečat“ (rubber-stamp). Drugi je adaptacijski scenarij, koji nadzorni kapacitet obnavlja razvojem evaluacijske pismenosti, pododborima za tehnologiju i unutarnjom revizijom kao trećom linijom obrane. Originalnost rada očituje se u razotkrivanju triju slijepih pjega u literaturi: dominacije jednostupanjskog modela upravljanja uz zanemarivanje dvostupanjskog sustava karakterističnog za Hrvatsku i kontinentalnu Europu, zanemarivanja patoloških pojava poput morokracije te pretpostavke o lakoj provjerljivosti algoritama. Glavna ograničenja rada odnose se na usmjerenost na odabranu reprezentativnu literaturu na engleskom i hrvatskom jeziku te izostanak primarne empirijske validacije izvedenih scenarija.

**Ključne riječi:** umjetna inteligencija, korporativno upravljanje, nadzorni odbor, fiducijarne dužnosti, unutarnja revizija.

## 1. UVOD

Korporativno upravljanje tradicionalno se definira kao sustav pravila, praksi i procesa kojima se trgovačka društva usmjeravaju i kontroliraju, s primarnim ciljem ublažavanja agencijskih sukoba te zaštite interesa dioničara i ostalih dionika (Fama i Jensen, 1983; Jensen i Meckling, 1976). U navedenom okviru središnju ulogu ima odbor (Tipurić, 2008), pri čemu dvostupanjski sustav, u kojem je uprava kao izvršno tijelo strogo odvojena od nadzornog odbora, predstavlja povijesno zastupljeniji odabir dioničkih društava u Republici Hrvatskoj (Tipurić i Cindrić, 2024). Za razliku od Hrvatske, u globalnom kontekstu prevladava jednostupanjski sustav na koji je usmjerena i glavnina relevantne literature o umjetnoj inteligenciji (UI). Zbog toga, pojedini teorijski i empirijski spoznajni uvidi o odnosu umjetne inteligencije i korporativnog upravljanja u hrvatskom okruženju mogu djelovati teško primjenjivima. Unatoč tom prividu, umjetna inteligencija predstavlja značajan transformacijski potencijal i izazov za sve oblike korporativnog upravljanja, zbog čega je potreban pojačan istraživački napor u ovom smjeru.

Štoviše, novija istraživanja ukazuju na to da primjena umjetne inteligencije postupno zamagljuje granice između upravljačkih i nadzornih funkcija jer smanjuje informacijsku asimetriju između ova dva tijela, što je, prema agencijskoj teoriji, pretpostavka postojanja korporativnog upravljanja (Agarwal, 2026; Mozzarelli i Schneider, 2026; Tipurić, Hruška i Kovač, 2026). Istodobno se povećava informacijska asimetrija prema samoj tehnologiji, odnosno dolazi do toga da članovi odbora nedovoljno razumiju unutarnju logiku i algoritamske procese modela kojima se koriste. U literaturi se taj procjep prepoznaje kao paradoks crne kutije, koji označava stanje u kojem povećano oslanjanje na neprozirne sustave umjetne inteligencije smanjuje mogućnost odbora da neovisno verificira i nadzire donesene odluke (Agnese, Arduino i Di Prisco, 2025; Mozzarelli i Schneider, 2026). U djelokrug tako shvaćenog odbora umjetna inteligencija ulazi iz dva smjera. Posredno, organizacije uvode umjetnu inteligenciju u svoje poslovanje, čime ona postaje izvorom novih strateških prilika, ali i rizika za dionike, dakle predmetom nadzorne odgovornosti odbora (Zhao, 2024). Neposredno, umjetna inteligencija se nudi samim odborima kao potpora odlučivanju (Agnese i sur., 2025; Ahdadou, Aajly i Tahrouch, 2025). Literatura koja prati taj dvostruki ulazak raste iznimno brzo, a velika većina relevantnih radova objavljena je između 2024. i 2026. godine. Rast literature, ipak, ne podrazumijeva i njezinu koherentnost. Postojeće sinteze se bave, uglavnom, onime oko čega postoji suglasje (Ahdadou i sur., 2025), dok područja na kojima se istraživači razilaze ostaju nedovoljno prepoznata. Neuočene rasprave vode do istodobnih istraživačkih programa koji se međusobno ne čuju i ne nadopunjuju. Glavna je svrha ovoga rada pružiti konceptualnu sintezu suprotstavljenih stajališta u literaturi te sistematizirati ključne teorijske, empirijske i normativne razlaze o odnosu odbora i umjetne inteligencije. Radi ostvarivanja navedene svrhe, rad postavlja dva istraživačka pitanja: (1) Koja suprotstavljena stajališta postoje u literaturi o odnosu odbora i umjetne inteligencije? (2) Oko kojih se osi te rasprave vode i na kojim teorijskim tradicijama počivaju pojedine pozicije? Rad je metodološki oblikovan kao kritički narativni pregled literature. Primjerenost narativnog pregleda je opravdana kada je cilj konceptualna sinteza i teorijska sistematizacija heterogenog brzorastućeg istraživačkog prostora, a ne iscrpna kvantitativna agregacija nalaza (Grant i Booth, 2009; Snyder, 2019). Ishodište analize čini pretraživanje baze Scopus provedeno u kolovozu 2026. godine kombinacijom ključnih pojmova vezanih uz odbore i umjetnu inteligenciju, dopunjeno relevantnom stručnom literaturom. Odabir radova je temeljen na

svrhovitosti, prema kriteriju zauzimanja prepoznatljive pozicije u raspravama o odnosu odbora i umjetne inteligencije. Pri tome, cilj nije bila iscrpnost korpusa, nego pokrivenost različitih stajališta. Osim što se pozicije prikazuju deskriptivno, analiziraju se i njihove teorijske pretpostavke, međusobna hijerarhija i slijepe pjege, što pregledu daje kritičku dimenziju. Nakon uvoda, drugi dio rada prikazuje temeljni teorijski i empirijski okvir odnosa odbora i umjetne inteligencije. Treće poglavlje izlaže tri središnje rasprave prepoznate u literaturi, dok četvrto poglavlje analizira njihovu hijerarhiju i slijepe pjege te iz njih izvodi smjernice za buduća istraživanja i ograničenja rada, nakon čega slijedi zaključak.

## 2. POJMOVNI I TEORIJSKI OKVIR

### 2.1. Pojmovno određenje umjetne inteligencije

Prije analize rasprava potrebno je razjasniti što literatura uopće podrazumijeva pod umjetnom inteligencijom, tim više što jedinstvene definicije nema ni u teoriji, a ni u zakonodavstvu (Abdelati Nasr, Ebed Emam, Adam Ahmed i Alshamrani, 2024; Coovadia, Marx, Botha i Gold, 2025). Za suvremeni korporativni diskurs najutjecajniji okvir postavila je stručna skupina Europske komisije, prema kojoj umjetna inteligencija predstavlja softverske, a potencijalno i hardverske sustave koje su dizajnirali ljudi i koji, zbog zadanog cilja, percipiraju okruženje, interpretiraju podatke, rezoniraju i odlučuju o najboljim akcijama (High-Level Expert Group on Artificial Intelligence, 2019; Hickman i Petrin, 2021). U praksi se umjetna inteligencija nerijetko poistovjećuje s algoritmima strojnog i dubokog učenja, koji uče prepoznavanjem statističkih obrazaca u podacima umjesto slijednog kodiranja (Mozzarelli i Schneider, 2026), a obuhvaća obradu prirodnog jezika, velike jezične modele, računalni vid i ekspertne sustave (Abdelati Nasr i sur., 2024; Schuett, 2025a). Ulogu i opseg djelovanja umjetne inteligencije u radu odbora literatura najčešće sistematizira Hilbovom (2020) taksonomijom pet scenarija prema stupnju autonomije stroja (Ahdadou i sur., 2025), kako je prikazano u Tablici 1.

**Tablica 1. Prikaz scenarija umjetne inteligencije prema stupnju autonomije**

| Stupanj autonomije | Stupanj kontrole | Primjena u odboru |
|---|---|---|
| Asistirana inteligencija | Puna kontrola; isključiva ljudska odgovornost | Automatizacija rutinskih i neanalitičkih zadataka. |
| Augmentirana inteligencija | Puna kontrola; UI savjetuje, čovjek odlučuje | Obrada masovnih podataka i simulacija strateških scenarija. |
| Amplificirana inteligencija | Zajedničko odlučivanje; podjela odgovornosti | Stroj generira preporuke koje čovjek formalno odobrava. |
| Autonomna inteligencija | Ograničena kontrola; opasnost od pravnog vakuuma | Stroj samostalno odlučuje u zadanom rasponu (npr. VITAL – autonomni algoritamski član). |
| Autopoietična inteligencija | Marginalizirana ili nepostojeća kontrola; izostanak ljudske odgovornosti | Samorazvijajući sustav koji samostalno širi područje odlučivanja. |

Izvor: prilagođeno prema Hilb (2020).

## 2.2. Fiducijarne veze odbora i umjetne inteligencije

Odnos odbora i umjetne inteligencije omeđen je tehnološkim mogućnostima s jedne te pravnim i društvenim ograničenjima s druge strane. Literatura tu napetost oblikuje kroz četiri veze koje ujedno čine teorijske okosnice iz kojih izrastaju rasprave analizirane u nastavku. Prva veza utemeljena je u teoriji augmentacije (Davenport i Kirby, 2016; Daugherty i Wilson, 2018). Ona polazi od pretpostavke komplementarnosti ljudskog uma i strojne inteligencije. Naime, odbori su pri analizi golemih količina korporativnih podataka izloženi kognitivnom preopterećenju pa algoritam preuzima obradu i strukturiranje informacija, čime se ljudima oslobađaju resursi za strateške i etičke prosudbe (Agnese i sur., 2025; Ahdadou i sur., 2025). Druga veza predstavlja pravno-normativnu protutežu tehnološkom optimizmu. Dok pravno-doktrinarna literatura naglašava nedelegabilnost fiducijarnih dužnosti i ističe da se temeljne obveze članova odbora, dužnost pažnje i dužnost lojalnosti, ne mogu prenijeti na algoritamske sustave (Hickman i Petrin, 2021; Möslein, 2025), empirijska istraživanja na tržištu kapitala i u organizacijama fokusiraju se na stvarni učinak uvođenja tehnologije na poslovanje i nadzor. Strateške odluke obilježene su strukturnom nepredvidivošću pa ih nije

moguće u cijelosti formalizirati optimizacijskim funkcijama (Mozzarelli i Schneider, 2026). Budući da umjetna inteligencija nema pravnu osobnost niti vlastitu imovinu, ne može snositi odgovornost, pa članovi upravljačkih i nadzornih tijela zadržavaju potpunu odgovornost za vođenje i nadzor društva (Möslein, 2025). Nekritičko oslanjanje na strojno generirane preporuke stoga predstavlja povredu dužnosti pažnje i izlaže direktore osobnoj imovinskoj odgovornosti (Hickman i Petrin, 2021). Empirijske studije utemeljene na teoriji signaliziranja objašnjavaju treću vezu te pokazuju da način na koji poduzeće provodi tehnološku transformaciju i nadzire umjetnu inteligenciju šalje signale investitorima (Connelly, Certo, Ireland i Reutzel, 2011). Četvrta veza vraća se na agencijsku teoriju (Jensen i Meckling, 1976). Empirijska istraživanja unutar agencijskog okvira potvrđuju da tehnologija može djelovati kao kontrolni mehanizam koji smanjuje agencijske troškove te usklađuje ponašanje menadžera s interesima dioničara (Saeed, 2025). Međutim, literatura upozorava da agencijski problem dobiva novu dimenziju ako nadzornom tijelu nedostaje osnovna razina digitalne pismenosti. U takvim uvjetima uprava može iskoristiti informacijsku asimetriju i neprozirnost modela u svoju korist, što izravno otvara prostor za tri središnje rasprave (Saeed, 2025; Tipurić i sur., 2026).

## 3. TRI SREDIŠNJE RASPRAVE O ODNOSU ODBORA I UMJETNE INTELIGENCIJE

Iz opisanih teorijskih veza u literaturi izranjaju tri središnje rasprave: prva se tiče mjesta odlučivanja, druga definicije samog problema, a treća institucionalne strukture nadzora. Svaka je rasprava u nastavku predstavljena kroz svoje središnje pitanje, dvije dominantne pozicije i istraživačke tradicije koje ih nose, pri čemu se odnos pozicija kreće od potpune suprotstavljenosti do komplementarnosti. Njihov usporedni sintetički prikaz dan je u Tablici 2.

**Tablica 2. Prikaz triju središnjih rasprava o odnosu odbora i umjetne inteligencije**

| Rasprava | Ključno pitanje | Dominantne pozicije i argumenti | Polje konvergencije |
|---|---|---|---|
| Rasprava o supstituciji prosudbe | Do kojeg je stupnja autonomije dopuštena supstitucija ljudske prosudbe strojem u odlučivanju? | Pristaše supstitucije: kognitivna ograničenja ljudi, optimizacija rezultata i eliminacija menadžerskog oportunizma. Protivnici supstitucije: nedelegabilnost dužnosti pažnje i lojalnosti, nepostojanje pravne osobnosti stroja i rizik osobne imovinske odgovornosti. | Algoritamsko zarobljavanje i pretvaranje odbora u „ljudske pečate“; rješenje je kognitivno jačanje fiducijara, inzistiranje na „objašnjivoj umjetnoj inteligenciji“ (xAI) i unutarnja revizija. |
| Rasprava o konceptualizaciji odnosa | Je li UI primarno resurs odbora (*governance with AI*) ili objekt nadzora i rizika (*governance of AI*)? | Instrumentalna paradigma: UI kao resurs za smanjenje agencijskih troškova, brže predikcije i osnaživanje neovisnih članova. Nadzorna paradigma: UI kao izvor novih poslovnih, alokacijskih, etičkih, reputacijskih i kibernetičkih rizika. | UI se mora promatrati i kao resurs i kao objekt nadzora; rješenje je razvoj „Upravljanja UI po dizajnu“, Korporativne digitalne odgovornosti (CDR) i „digitalne mudrosti odbora“. |
| Rasprava o nadzornom kapacitetu | Može li nadzorni odbor djelotvorno nadzirati upravu u uvjetima visoke UI složenosti? | Strukturni deficit: morokracija, operativni i informacijski monopol uprave, jaz u UI pismenosti i opasnost od tihe uzurpacije moći od strane IT stručnjaka. Adaptivni kapacitet: evaluacijska i proceduralna pismenost, odbori za tehnologiju i unutarnja revizija kao treća linija obrane. | Primjena Pravila poslovne prosudbe (*Business Judgment Rule*) zahtijeva da nadzorni odbor aktivira unutarnju reviziju te izbjegne slijepo odobravanje odluka uprave. |

## 3.1. Rasprava o supstituciji prosudbe

Okosnica ove rasprave je stupanj autonomije umjetne inteligencije, koja prema Hilbu (2020) seže od asistirane inteligencije do vizija o potpuno autopoietičnim korporativnim entitetima (Ahdadou i sur., 2025; Hilb, 2020). Na ovom teorijskom polju suprotstavljaju se dvije struje. Prva struja su pristaše supstitucije koji svoje argumente temelje na premisi da ljudski fiducijari, usprkos profesionalnoj ekspertizi, pate od značajnih kognitivnih ograničenja, selektivne percepcije, skrivenih bihevioralnih pristranosti (Agnese i sur., 2025; Hickman i Petrin, 2021), kao i „paralize analizom", gdje ljudski članovi odbora nisu sposobni pravovremeno obraditi goleme skupove nestrukturiranih informacija (Ahdadou i sur., 2025; Zhao i Gómez Fariñas, 2023). U tom smislu, prenošenje diskrecijskog prava odlučivanja na napredne sustave umjetne inteligencije predstavlja fiducijarnu nužnost za optimizaciju poslovnih rezultata i zaštitu prava dioničara (Agarwal, 2026). Najekstremniji oblik ovog pola očituje se u teorijskom i praktičnom dizajnu Decentraliziranih autonomnih organizacija (DAO), u kojima se fiducijarne dužnosti i upravljanje imovinom u potpunosti kodiraju u determinističke pametne ugovore (*smart contracts*) na *blockchainu* (Ibragimov, Abdusamiyeva, Yusupov, Mustafakulov, Jurayeva, Barnoeva i Alimova, 2026; Möslein, 2025). Druga struja je utemeljena na postulatima korporativnog prava i teorije odlučivanja (Hickman i Petrin, 2021; Mozzarelli i Schneider, 2026). Protuargument ove rasprave leži u razlikovanju determinističkih operacija optimizacije od naravi strateških odluka, koje su obilježene visokim stupnjem strukturne nepotpunosti (incompleteness) i nepredvidivosti (Alvarez i Porac, 2020; Mozzarelli i Schneider, 2026). One zahtijevaju primjenu „supstantivne racionalnosti", što uključuje moralno vaganje suprotstavljenih interesa dionika, društvenu odgovornost, etičku svijest i osjećaj za pravičnost, atribute koje umjetna inteligencija ne posjeduje niti ih može kognitivno replicirati (Agnese i sur., 2025; Hickman i Petrin, 2021). Kako dokazuju Mozzarelli i Schneider (2026), usporedba ljudskog i strojnog odlučivanja zapravo je kategorijalna pogreška jer strojevi donose predvidive, statistički optimizirane kalkulacije na temelju povijesnih podataka (*garbage in, garbage out*), dok ljudi posjeduju kognitivnu svestranost i moralnu savjest potrebnu za navigaciju kroz radikalnu neizvjesnost i donošenje vrijednosnih sudova. Korporativno pravo kontinentalne Europe (kao i anglosaksonska tradicija) povjerava vođenje i nadzor društva isključivo fizičkim (prirodnim) osobama (Article 2:140(2) DCC; Hilb, 2020; Möslein, 2025). Budući da algoritam nema pravnu osobnost, moralnu savjest niti vlastitu imovinu, on ne

može snositi odgovornost za nastalu štetu (Gramitto Ricci, 2019; Hickman i Petrin, 2021). Slijepo i nekritičko oslanjanje članova odbora na neprozirne preporuke „crne kutije“ ne može se opravdati Pravilom poslovne prosudbe (*Business Judgment Rule*) i predstavlja izravnu, svjesnu povredu dužnosti pažnje, što izlaže članove odbora osobnoj, neograničenoj i solidarnoj imovinskoj odgovornosti pred dioničarima i sudom (Hickman i Petrin, 2021; Möslein, 2025; Mozzarelli i Schneider, 2026). Premda pravni propisi (poput EU AI Act-a, GDPR-a Art. 22 ili DORA-e) inzistiraju na modelu „čovjeka u petlji” (*human-in-the-loop*) i „čovjeka u zapovjedništvu” (*human-in-command*) kako bi se očuvao integritet odgovornosti, u praksi se javlja ozbiljan bihevioralni i kognitivni paradoks (Bello y Villarino i Bronitt, 2024; Hickman i Petrin, 2021; Mozzarelli i Schneider, 2026) koji se manifestira kroz kognitivno preopterećenje i „algoritamsko zarobljavanje“ ljudskog nadzornika (Mozzarelli i Schneider, 2026; Tipurić i sur., 2026). Kada se članovima odbora, koji dokazano pate od niskog stupnja digitalne pismenosti (Tipurić i sur., 2026), prezentiraju složeni matematički inputi koje generiraju modeli, oni nisu sposobni provesti kognitivno zahtjevnu provjeru pretpostavki i ograničenja tih sustava (Möslein, 2025; Tipurić i sur., 2026). Suočeni s asimetrijom informacija i strahom od pogreške, članovi odbora razvijaju tendenciju mehaničkog, nesvjesnog prihvaćanja i odobravanja strojnih odluka (Keding i Meissner, 2021; Tipurić i sur., 2026). U takvim uvjetima, odbori postupno gube svoju stratešku, nadzornu i resursnu funkciju te postaju ljudski pečati (*rubber-stamp*) (Bello y Villarino i Bronitt, 2024; Mozzarelli i Schneider, 2026; Tipurić i sur., 2026). Oportunitetni trošak takve birokratske reifikacije je mutacija tradicionalnog agencijskog problema u novu asimetriju prema samoj tehnologiji, iako je asimetrija između ljudi potencijalno smanjena (Bello y Villarino i Bronitt, 2024; Tipurić i sur., 2026). Stoga, literatura upozorava na to da se regulativa mora preusmjeriti na kognitivno jačanje ljudskog donositelja odluka te uvođenje robusnih i neovisnih unutarnjih revizijskih kontrola (modela triju linija obrane) koje mogu osigurati provjerljivost i objašnjivost modela izravno za potrebe odbora (Bello y Villarino i Bronitt, 2024; Mozzarelli i Schneider, 2026; Schuett, 2025a, 2025b).

## 3.2. Rasprava o konceptualizaciji odnosa odbora i umjetne inteligencije

Rasprava se, u suštini, lomi oko fundamentalnog pitanja svrhe i uloge tehnologije u odborima (Gan, Wilczek-Stronczek i Papasava, 2026; van Giffen i Ludwig, 2023). Pregled literature pokazuje da različiti izvori adresiraju dva odvojena aspekta iste teme. Ti se aspekti konkretno odnose na sljedeća problemska pitanja: je li umjetna inteligencija primarno resurs odbora i njegov alat čije korištenje donosi novu vrijednost nadograđujući kognitivne kapacitete odbora (*AI for the board* ili *governance with AI*), ili je ona, u svojoj osnovi, složeno ishodište organizacijskih, etičkih i regulatornih rizika koji pred odbor stavlja novu, iznimno zahtjevnu nadzornu obvezu (*governance of AI*) (Hilb, 2020; van Giffen i Ludwig, 2023)? U ovoj raspravi ne sudjeluju suprotstavljene pozicije u strogom smislu, nego dvije dominantne, međusobno komplementarne perspektive: instrumentalna i nadzorna paradigma. Instrumentalna paradigma umjetnu inteligenciju promatra kao resurs koji omogućuje vrijednost odboru (*value enabler*), dok nadzorna paradigma umjetnu inteligenciju konceptualizira kao objekt nadzora (*risk object*) (Gan i sur., 2026; Hilb, 2020). Za razliku od prve rasprave, ovdje je riječ o latentnoj raspravi. Različite pozicije rijetko ulaze u domenu one druge, premda i takva istraživanja postoje. Instrumentalna paradigma svoje ishodište temelji u resursnoj teoriji (Barney, 1991) i teoriji augmentacije (Davenport i Kirby, 2016; Daugherty i Wilson, 2018). Stoga se umjetna inteligencija ovdje poima kao ključni nematerijalni resurs koji izravno unapređuje rad odbora i kvalitetu korporativnog upravljanja (Agnese i sur., 2025; Ahdadou i sur., 2025). Ova se paradigma oslanja na model „strojeva za predviđanje" (*prediction machines*) (Agrawal, Gans i Goldfarb, 2018), gdje umjetna inteligencija značajno smanjuje troškove predviđanja i obrade masovnih skupova podataka (*big data*). Argumentacija instrumentalne paradigme oblikuje se kroz tri ključna argumenta: unaprjeđenje kvalitete strateških odluka, smanjenje agencijskih troškova i rano prepoznavanje anomalija te osnaživanje neovisnih članova odbora. Tako Agarwal (2026) u svojoj empirijskoj studiji pokazuje da uvođenje agentne umjetne inteligencije (*Agentic AI*) ima statistički značajan pozitivan utjecaj na kvalitetu odlučivanja na razini odbora smanjujući informacijski jaz i omogućujući *evidence-based* vodstvo. Osim toga, pristup ističe da umjetna inteligencija djeluje kao moćan mehanizam kontrole menadžerskog oportunizma (Ahdadou i sur., 2025; Saeed, 2025). Implementacija sustava automatskog donošenja odluka i automatiziranih sustava upravljanja usklađenošću (Bello y Villarino i Bronitt,

2024) omogućuje automatsko prepoznavanje manipulacija dobiti, financijskih prevara i kršenja regulatornih normi, čime se štete sprječavaju *ex ante, a ne ex post* (Saeed, 2025; Zhang, Yoo, Lyytinen i Lindberg, 2021). Instrumentalni alati umjetne inteligencije omogućuju članovima izravan i nepristran uvid u glavne informacije od njihovog interesa, smanjujući im ovisnost o informacijama koje im selektivno servira izvršni menadžment (Ahdadou i sur., 2025). Nasuprot instrumentalnom pristupu, nadzorna paradigma stvara oštar teorijski i fiducijarni zaokret. Ovaj pristup upozorava da je umjetna inteligencija izvor novih, krajnje složenih i moguće katastrofalnih organizacijskih, etičkih, pravnih i reputacijskih rizika (Gan i sur., 2026; Schuett, 2025a; van Giffen i Ludwig, 2023). Motivacija zastupnika ove paradigme leži u spoznaji da neusmjerena i nekontrolirana umjetna inteligencija izlaže korporaciju nepoznatim i visoko destabilizirajućim opasnostima (Coovadia i sur., 2025; Hudson i Morgan, 2026). Van Giffen i Ludwig (2023) identificirali su četiri ključne grupe nadzornih pitanja (*board-level AI governance issues*) s kojima se odbori moraju suočiti. Prvo značajno pitanje tiče se poslovnog modela i strateške konkurentnosti. Osim toga, otvara se pitanje i alokacije kapitala te nezabilježenih ulaganja (*lock-in effects*). Treće je nadzor nad rizicima koji su svojstveni umjetnoj inteligenciji poput pristranosti (*machine bias*), kršenja privatnosti podataka (GDPR), kibernetičkih ranjivosti, generiranja lažnih informacija te opasnosti od narušavanja ugleda korporacije (Coovadia i sur., 2025; Pazdera, 2026; van Giffen i Ludwig, 2023). Kao zadnje pitanje nameće se izgradnja tehnološke kompetencije koja podrazumijeva da sudionici s obje strane agencijskog spektra posjeduju adekvatno znanje za prepoznavanje i ublažavanje algoritamskih opasnosti (Keijzer i Lafarre, 2025; van Giffen i Ludwig, 2023). Literatura adresira još nekoliko važnih problema koji bi trebali zanimati odbore. Tako Hudson i Morgan (2026) vodeći se postulatima teorije signaliziranja, pronalaze empirijski nalaz da izloženost umjetnoj inteligenciji smanjuje percepciju rizika na tržištu, ali njezina interakcija s heterogenim mrežama odbora u tehnološki najnaprednijim industrijama može poslati negativan signal investitorima i povećati idiosinkratski rizik ako tržište procijeni da poduzeće riskira izvan svojih ključnih kompetencija (Hudson i Morgan, 2026). Pregled analizirane literature ukazuje na to da instrumentalna i nadzorna paradigma ne smiju se promatrati kao opozicije, nego kao dva nerazdvojna stupa jedinstvene nadzorne odgovornosti odbora (Gan i sur., 2026; Hilb, 2020; van Giffen i Ludwig, 2023). U ovoj zoni preklapanja razvija se koncept „Upravljanja umjetnom inteligencijom po dizajnu"

(*AI Governance by Design*) (Agarwal, 2026; Gan i sur., 2026) kao i etički okviri utemeljeni na stakeholderskoj teoriji (Freeman, 1984; Coovadia i sur., 2025). U konačnici, na međi ovih dviju paradigmi izrasta ideja o redefiniciji same svrhe korporacije: umjesto pritiska za maksimizacijom dioničke vrijednosti prema izgradnji dugoročne intrinzične vrijednosti poduzeća (Grove i Lockhart, 2019; Grove i sur., 2020) u okviru sveobuhvatne digitalne odgovornosti (*Corporate Digital Responsibility - CDR*) (Möslein, 2025; Pazdera, 2026).

## 3.3. Rasprava o nadzornom kapacitetu odbora

Treća temeljna rasprava oblikuje se unutar nadzorne paradigme koja je predmet prethodne rasprave. Fokus je na jednom od najkompleksnijih fiducijarnih pitanja u ovom kontekstu, koje se odnosi na mogućnost i djelotvornost nadzora nad upravom u uvjetima visoke tehnološke složenosti (Bello y Villarino i Bronitt, 2024; Möslein, 2025; Tipurić i sur., 2026; van Giffen i Ludwig, 2023). U dvostupanjskom sustavu korporativnog upravljanja, nadzorni mehanizmi postavljeni su tako da nadzorni odbor može periodički kontrolirati rad uprave analizom financijskih izvješća, poslovnih planova i internih revizijskih nalaza (Hilb, 2020). Ipak, masovno uvođenje sustava umjetne inteligencije u operativno i strateško poslovanje narušava ovu ravnotežu (Agnese i sur., 2025; Tipurić i sur., 2026). Središnje pitanje ove rasprave stoga glasi: može li nadzorni odbor, kao neizvršno tijelo čije fundamentalne postavke poput sastava, informacijskih kanala, kognitivnih rutina i pravnih okvira kronološki prethode širokoj primjeni umjetne inteligencije, djelotvorno nadzirati upravu u pogledu cjelokupne korporativne agende o umjetnoj inteligenciji (Bello y Villarino i Bronitt, 2024; Mozzarelli i Schneider, 2026; Tipurić i sur., 2026; van Giffen i Ludwig, 2023)? U literaturi se oko ovog pitanja teorijska i empirijska stajališta polariziraju na one koji upozoravaju na duboki strukturni deficit nadzornog kapaciteta te one koji zagovaraju adaptivni nadzorni kapacitet kroz kognitivno-edukacijsku prilagodbu, digitalnu rekompoziciju odbora te aktivaciju unutarnje revizije kao neovisne treće linije obrane (Keijzer i Lafarre, 2025; Schuett, 2025a; Tipurić i sur., 2026). Zagovornici prvog stajališta naglašavaju da je primjena umjetne inteligencije stvorila krajnju neravnotežu moći u korist uprave, pri čemu je stvarni kapacitet nadzornog odbora za provođenje neovisnog nadzora doveden u pitanje (Abdelati Nasr i sur., 2024; Mozzarelli i Schneider, 2026; Tipurić i sur., 2026). Tako uprava postiže operativni, kognitivni i

informacijski monopol nad podatkovnim tokovima i modelima predviđanja (Tipurić i sur., 2026). Istražujući ovaj odnos na uzorku hrvatskih poduzeća, Tipurić i sur. (2026) zaključuju da postoji statistički značajan jaz u UI pismenosti između ovih dvaju tijela, pri čemu je UI pismenost nadzornih odbora statistički značajno niža od operativne UI kompetencije članova uprave. Zaostajanje nadzornih odbora za upravom i postojanje visoke informacijske asimetrije Tipurić (2025) objašnjava „morokracijom", definirajući je kao upravljački sustav u kojemu se kroz selekciju članova po kriteriju lojalnosti svjesno potiskuje kompetencija na razini odbora u korist poslušnosti upravljačkim elitama (Tipurić, 2025; Tipurić i sur., 2026). U tako oblikovanim odborima stjecanje tehnološke pismenosti i postavljanje kritičkih pitanja o umjetnoj inteligenciji i sličnim strateškim pitanjima tretira se kao nepoželjno ponašanje koje narušava uspostavljeni konformizam (Tipurić i sur., 2026). U konačnici takvi pritisci dovode do „motiviranog nepripremanja" i strateškog neznanja jer isto istraživanje utvrđuje da, iako članovi odbora formalno uočavaju važnost buduće spremnosti za nadzor nad UI, njihov je stvarni operativni kapacitet za ovo pitanje u praksi nepostojeći (Tipurić i sur., 2026). Abdelati Nasr i sur. (2024) i Pazdera (2026) upozoravaju na prelijevanje upravljačke moći na voditelje IT odjela i vanjske dobavljače u trenutku kada i uprava i nadzorni odbori izgube kontrolu nad nadzorom sustava umjetne inteligencije, uslijed čega tehnički stručnjaci postaju *de facto* direktori u praksi jer kontroliraju ulazne podatke i algoritamska pravila. Ipak, na drugom kraju spektra ove rasprave nalaze se istraživanja koja dokazuju nadzorni odbori mogu uspješno redefinirati svoj nadzorni kapacitet te razviti adaptacijski kapacitet kroz tri komplementarne dimenzije. Prva dimenzija je kognitivno-edukacijska čije je temeljno uporište podizanje UI pismenosti na razini cijelog nadzornog odbora (Tipurić i sur., 2026; van Giffen i Ludwig, 2023). UI pismenost koja se zahtijeva od nadzornih odbora nije tehnička (Keijzer i Lafarre, 2025; Tipurić i sur., 2026), nego evaluacijska i proceduralna. Drugim riječima, od odbora se očekuje da razvije sposobnost postavljanja pravih, kritičkih pitanja upravi (Tipurić i sur., 2026; van Giffen i Ludwig, 2023). Druga dimenzija kroz koju odbori mogu redefinirati nadzorni kapacitet je strukturna rekonstrukcija odbora kroz uspostavu specijaliziranih radnih tijela (Keijzer i Lafarre, 2025; Weill i sur., 2019). Analizirajući 255 biografija članova odbora u 18 vodećih uvrštenih kompanija u Nizozemskoj (AEX-25) primjenom metode tekstualnog rudarenja te Weillove skale digitalne pismenosti (*digitally savvy boards*), Keijzer i Lafarre (2025) razotkrivaju značajan deficit: čak četiri od 18

analiziranih odbora nemaju niti jednog člana s digitalnim kompetencijama (Keijzer i Lafarre, 2025). Ipak, isto istraživanje dokumentira i trend adaptacije jer je udio organizacija sa specijaliziranim Odborom za tehnologiju i digitalizaciju pri nadzornom tijelu porastao s 11 % u 2022. na 33 % u 2025. godini. Zaključno, treća dimenzija prilagodbe podrazumijeva uvođenje modela triju linija obrane te aktivaciju neovisne funkcije unutarnje revizije za umjetnu inteligenciju (Schuett, 2025a, 2025b). Specifičnost unutarnje revizije leži u tome da izravno odgovara nadzornom odboru, a ne upravi te tako djeluje kao njegove neovisne „oči i uši" u poduzeću (Schuett, 2025a). Unutarnji revizori podnose neovisna izvješća nadzornom odboru po pitanju evaluacije modela umjetne inteligencije koje uprava koristi, kvalitete ulaznih podataka, otpornosti na pristranosti i slično (Schuett, 2025a, 2025b). Sukus ove rasprave ukazuje na to da je djelotvoran nadzorni odbor u kontekstu umjetne inteligencije onaj koji gradi hibridni ekosustav nadzorne pismenosti i kontrolnih kanala (Tipurić i sur., 2026; van Giffen i Ludwig, 2023). Pravna argumentacija ovog sukusa proizlazi iz Pravila poslovne prosudbe (*Business Judgment Rule*), koje je općeprihvaćeno i u kontinentalnom pravu društava (Hickman i Petrin, 2021; Möslein, 2025). Po ovom pravilu, članovi nadzornog odbora oslobođeni su od osobne imovinske odgovornosti za odluke ili nadzorne propuste samo ako dokažu da su nadzor nad upravom provodili na temelju razumno dostupnih informacija, neovisno provjerenih izvješća i uz dužnu pažnju (Hickman i Petrin, 2021; Möslein, 2025; Schuett, 2025a).

# 4. HIJERARHIJA RASPRAVA, SLIJEPE PJEGE, SMJERNICE I OGRANIČENJA RADA

## 4.1. Hijerarhija i međusobna uvjetovanost rasprava

Sučeljavanje triju rasprava, provedeno u ovom radu, vodi jedinstvenom zaključku. Umjetna inteligencija za odbore predstavlja socio-tehnički preokret koji istodobno dovodi u pitanje tko odlučuje (subjekt), čemu tehnologija služi (svrha) i može li nadzorni odbor uopće nadzirati upravu (kapacitet) (Gan i sur., 2026; Hilb, 2020; Mozzarelli i Schneider, 2026). Analiza provedena u radu pokazuje da ove tri rasprave nisu neovisne jer odgovor na prvo pitanje diktira druga dva, pa se iz njihovih krajnosti sklapaju dva cjelovita scenarija budućnosti korporativnog upravljanja. Prva rasprava o supstituciji prosudbe predstavlja uzročnu i temeljnu os jer stav o

nedelegabilnosti fiducijarnih dužnosti izravno određuje hoće li se umjetna inteligencija u drugoj raspravi tretirati primarno kao resurs ili kao objekt rizika, što u trećoj raspravi konačno determinira potreban nadzorni kapacitet i strukturu neizvršnog tijela. Prvi je patološki scenarij koji započinje supstitucijom ljudske prosudbe, što svodi tehnologiju na instrument efikasnosti izostavljajući u potpunosti nadzorni aspekt. Zbog dubokog jaza u pismenosti, nadzorni odbor završava u algoritamskom zarobljavanju i služi kao pečat za odluke koje donosi uprava ili umjetna inteligencija, a stvarna moć neprimjetno klizi prema tehno-strukturama u poduzeću (Abdelati Nasr i sur., 2024; Tipurić i sur., 2026). Drugi je adaptacijski scenarij koji kreće od nedelegabilnosti fiducijarnih dužnosti (Hickman i Petrin, 2021) i utemeljuje dvojnu paradigmu upravljanja s tehnologijom i nad njom. U konačnici umjetnu inteligenciju operacionalizira kroz evaluacijsku pismenost, specijalizirane pododbore za tehnologiju te unutarnju reviziju kao treću liniju obrane koja ruši informacijski monopol uprave (Keijzer i Lafarre, 2025; Schuett, 2025a).

## 4.2. Slijepe pjege u literaturi

Sinteza analiziranih radova razotkriva tri ključne slijepe pjege u dosadašnjem znanstvenom diskursu koje ograničavaju razumijevanje ove problematike. Prva je dominacija jednostupanjskog modela korporativnog upravljanja i zanemarivanje dvostupanjskog sustava. Glavnina analiziranih radova usmjerena je na anglosaksonski jednostupanjski sustav, pri čemu ostaje nedovoljno istraženo kako umjetna inteligencija utječe na specifične informacijske i nadzorne kanale između uprave i nadzornog odbora u dvostupanjskom modelu. Zbog toga su postojeći teorijski i empirijski uvidi samo djelomično primjenjivi u okruženju poput hrvatskog. Druga je zanemarivanje postojanja patoloških oblika upravljanja, poput morokracije. U analiziranim radovima nerijetko se pretpostavlja da odbori prirodno teže stjecanju digitalnih kompetencija, zanemarujući „izopačene“ oblike upravljanja u kojima se kroz selekciju članova po kriteriju lojalnosti svjesno potiskuje kompetencija u korist poslušnosti, što dovodi do motiviranog nepripremanja i strateškog neznanja (Tipurić, 2025; Tipurić i sur., 2026). I konačno, analizirani radovi, ali i postojeća pravna infrastruktura pretpostavljaju da su algoritamski ulazi objektivni i lako provjerljivi, zanemarujući paradoks u kojem kognitivno preopterećenje pretvara odbore u

„ljudske pečate“ (*rubber-stamp*) koji „na slijepo“ pečatiraju odluke koje im uprava uz pomoć umjetne inteligencije donosi.

## 4.3. Ograničenja i smjernice za buduća istraživanja

Tumačenje nalaza ove sinteze potrebno je promatrati kroz nekoliko ograničenja. Prvo, istraživanje bilo je usmjereno na odabranu reprezentativnu znanstvenu i stručnu literaturu s težištem na radovima objavljenima do kolovoza 2026. godine. Drugo, u analizu su uključeni isključivo recenzirani radovi objavljeni na engleskom i hrvatskom jeziku, čime je ostavljena mogućnost izostavljanja spoznaja iz drugih jezičnih i pravnih područja. Zaključno, rad je oblikovan kao kvalitativna konceptualna sinteza rasprava, a ne kao kvantitativna meta-analiza, što podrazumijeva interpretativni pristup analiziranim stavovima i teorijskim okvirima, pri čemu glavno metodološko ograničenje predstavlja izostanak primarne empirijske validacije izvedenih scenarija i teorijskih modela. Na temelju uočenih slijepih pjega i teorijskih okvira, predlaže se provođenje kvalitativnih studija slučaja i dubinskih intervjua s članovima nadzornih odbora u kontinentalnoj Europi i Hrvatskoj kako bi se izmjerio stvarni učinak primjene modela triju linija obrane (3LoD) i unutarnje revizije za umjetnu inteligenciju na informacijsku asimetriju. Nužno je, osim toga, razviti nove teorijske modele koji objašnjavaju mutaciju agencijskog problema i asimetriju prema samoj tehnologiji, uz razradu okvira Korporativne digitalne odgovornosti (CDR) na razini odbora. Konačno, za daljnji razvoj spoznaja i preporuka za praksu, obvezno je razviti i empirijski validirati standardizirane instrumente za procjenu evaluacijske i proceduralne UI pismenosti neizvršnih direktora i članova nadzornih odbora.

# 5. ZAKLJUČAK

Rad pruža konceptualnu sintezu suvremenih znanstvenih i stručnih rasprava o ulozi umjetne inteligencije u korporativnim odborima. Sinteza literature pokazuje da uvođenje umjetne inteligencije otvara tri usko povezana pitanja: tko donosi odluke (subjekt), čemu tehnologija služi (svrha) te raspolaže li neizvršno tijelo kapacitetom za djelotvoran nadzor nad upravom. Iz odgovora na ta pitanja oblikuju se dva oprečna scenarija budućnosti korporativnog upravljanja. Prvi je patološki scenarij u kojem nekritička supstitucija ljudske prosudbe i nizak stupanj digitalne pismenosti vode do algoritamskog

zarobljavanja odbora. Drugi je adaptacijski scenarij koji polazi od neupitne pravne nedelegabilnosti fiducijarnih dužnosti. Prema ovom scenariju, odbor uspostavlja dvojnu paradigmu upravljanja, s tehnologijom i nad njom. Teorijski i praktični doprinos rada očituje se u razotkrivanju triju slijepih pjega u dosadašnjem znanstvenom diskursu: dominacije jednostupanjskog modela uz zanemarivanje dvostupanjskog sustava karakterističnog za Hrvatsku, ignoriranja patoloških pojava poput morokracije te pretpostavke o lakoj provjerljivosti algoritama. Ključna normativna poruka rada jest da umjetna inteligencija ne smije poslužiti kao zaklon od osobne imovinske odgovornosti onih koji bi je trebali imati niti zamijeniti ljudsku prosudbu. Njezina je uloga ući u službu osnaživanja kognitivnih kapaciteta fiducijara i očuvanja upravljačke mudrosti (*board wisdom*) radi dugoročne održivosti poduzeća.

## LITERATURA

Abdelati Nasr, H. M., Ebed Emam, M. I., Adam Ahmed, M. E. i Alshamrani, A. S. (2024). The role of artificial intelligence in supporting commercial companies governance. *Journal of Ecohumanism, 3(4)*, 754-770. https://doi.org/10.62754/joe.v3i4.3587

Agarwal, I. (2026). Agentic artificial intelligence in corporate governance: Transforming board leadership through autonomous intelligence and adaptive decision-making. *Journal of Intelligent Decision Making and Information Science, 3(4s)*, 1513-1536. https://doi.org/10.59543/jidmis.v3.1174

Agnese, P., Arduino, F. R. i Di Prisco, D. (2025). The era of artificial intelligence: What implications for the board of directors? *Corporate Governance (Bingley), 25(2)*, 272-287. https://doi.org/10.1108/CG-06-2023-0259

Agrawal, A., Gans, J. i Goldfarb, A. (2018). *Prediction machines: The simple economics of artificial intelligence.* Boston, MA: Harvard Business Press.

Ahdadou, M., Aajly, A. i Tahrouch, M. (2025). Enhancing corporate governance through AI: A systematic literature review. *Technology Analysis and Strategic Management, 37(11)*, 1753-1766. https://doi.org/10.1080/09537325.2024.2326120

AI HLEG - High-Level Expert Group on Artificial Intelligence. (2019). Ethics guidelines for trustworthy AI. Bruxelles: European Commission.

Alvarez, S. A. i Porac, J. (2020). Imagination, indeterminacy, and managerial choice at the limit of knowledge. *Academy of Management Review, 45(4)*, 735-744. https://doi.org/10.5465/amr.2020.0366

Barney, J. (1991). Firm resources and sustained competitive advantage. *Journal of Management, 17(1)*, 99-120. https://doi.org/10.1177/014920639101700108

Bello y Villarino, J.-M. i Bronitt, S. (2024). AI-driven corporate governance: A regulatory perspective. *Griffith Law Review, 33(4)*, 355-374. https://doi.org/10.1080/10383441.2024.2405752

Connelly, B. L., Certo, S. T., Ireland, R. D. i Reutzel, C. R. (2011). Signaling theory: A review and assessment. *Journal of Management, 37(1)*, 39-67. https://doi.org/10.1177/0149206310388419

Coovadia, H., Marx, B., Botha, I. i Gold, N. O. (2025). Building an ethical artificial intelligence corporate governance framework for the integration of emerging technologies into business processes. *South African Journal of Accounting Research, 39(3)*, 286-316. https://doi.org/10.1080/10291954.2025.2523661

Daugherty, P. R. i Wilson, H. J. (2018). Human + machine: Reimagining work in the age of AI. Boston, MA: Harvard Business Review Press.

Davenport, T. H. i Kirby, J. (2016). Only humans need apply: Winners and losers in the age of smart machines. New York, NY: HarperCollins.

Fama, E. F. i Jensen, M. C. (1983). Separation of ownership and control. *The Journal of Law & Economics, 26(2)*, 301-325. https://doi.org/10.1086/467037

Freeman, R. E. (1984). Strategic management: A stakeholder approach. Boston, MA: Pitman.

Gan, K. C. J., Wilczek-Stronczek, B. i Papasava, A. (2026). Governing the algorithm: A conceptual review of strategic AI oversight in global corporations. AI and Society. https://doi.org/10.1007/s00146-026-03207-2

Gramitto Ricci, S. A. (2019). Artificial agents in corporate boardrooms. Cornell Law Review, 105(3), 869-908.

Grant, M. J. i Booth, A. (2009). A typology of reviews: An analysis of 14 review types and associated methodologies. *Health Information and Libraries Journal, 26(2)*, 91-108. https://doi.org/10.1111/j.1471-1842.2009.00848.x

Grove, H., Clouse, M., Schaffner, L. i Xu, T. (2020). Monitoring AI progress for corporate governance. *Journal of Governance and Regulation, 9(1)*, 8-17. https://doi.org/10.22495/jgrv9i1art1

Grove, H. i Lockhart, J. (2019). Evolution of corporate governance towards intrinsic value. *Corporate Law and Governance Review, 1(1)*, 8-15. https://doi.org/10.22495/clgrv1i1p1

Hickman, E. i Petrin, M. (2021). Trustworthy AI and corporate governance: The EU's ethics guidelines for trustworthy artificial intelligence from a company law perspective. *European Business Organization Law Review, 22(4)*, 593-625. https://doi.org/10.1007/s40804-021-00224-0

Hilb, M. (2020). Toward artificial governance? The role of artificial intelligence in shaping the future of corporate governance. *Journal of Management and Governance, 24(4)*, 851-870. https://doi.org/10.1007/s10997-020-09519-9

Hudson, K. i Morgan, R. E. (2026). Industry exposure to artificial intelligence, board network heterogeneity, and firm idiosyncratic risk. *Journal of Management Studies, 63(2)*, 596-630. https://doi.org/10.1111/joms.13127

Ibragimov, A., Abdusamiyeva, D., Yusupov, I., Mustafakulov, D., Jurayeva, S., Barnoeva, M. i Alimova, S. (2026). The role of algorithmic fiduciaries in decentralized autonomous organizations and the assignment of duty and developer liability for autonomous smart governance. *Indian Journal of Information Sources and Services, 16(2)*, 311-318. https://doi.org/10.51983/ijiss-2026.16.2.31

Jensen, M. C. i Meckling, W. H. (1976). Theory of the firm: Managerial behavior, agency costs and ownership structure. *Journal of Financial Economics, 3(4)*, 305-360. https://doi.org/10.1016/0304-405X(76)90026-X

Keding, C. i Meissner, P. (2021). Managerial overreliance on AI-augmented decision-making processes: How the use of AI-based advisory systems shapes choice behavior in R&D investment decisions. *Technological Forecasting and Social Change, 171*, 120970. https://doi.org/10.1016/j.techfore.2021.120970

Keijzer, T. i Lafarre, A. (2025). Technology expertise in the Dutch boardroom: Legal and text analytical findings. *Tilburg Law Review, 30(2)*, 25-46. https://doi.org/10.5334/tilr.418

Möslein, F. (2025). European company law in the age of digital transformation: Artificial intelligence, data economy, and digital corporate governance. *ERA Forum, 26(4)*, 629-646. https://doi.org/10.1007/s12027-025-00864-6

Mozzarelli, M. i Schneider, G. (2026). AI and strategic decisions: Facing the incompleteness. *European Business Organization Law Review*. https://doi.org/10.1007/s40804-025-00356-7

Pazdera, M. (2026). Rethinking corporate responsibility in the age of artificial intelligence. *Ethics and Bioethics (in Central Europe), 16(1-2)*, 77-90. https://doi.org/10.2478/ebce-2026-0006

Saeed, U. F. (2025). Can artificial intelligence and blockchain condition governance mechanisms to restrict earnings management? *SN Business and Economics, 5(12)*. https://doi.org/10.1007/s43546-025-00973-x

Schuett, J. (2025a). Frontier AI developers need an internal audit function. *Risk Analysis, 45(6)*, 1332-1352. https://doi.org/10.1111/risa.17665

Schuett, J. (2025b). Three lines of defense against risks from AI. *AI and Society, 40(2)*, 493-507. https://doi.org/10.1007/s00146-023-01811-0

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

Tipurić, D. (2008). Korporativno upravljanje. Zagreb: Sinergija.

Tipurić, D. (2025). Morocracy. *Ekonomski pregled, 76(6)*, 482-502. https://doi.org/10.32910/ep.76.6.5

Tipurić, D. i Cindrić, L. (2024). Nadzorni odbor: korporativno upravljanje i grupna dinamika. Zagreb: Sinergija.

Tipurić, D., Hruška, D. i Kovač, I. (2026). Board-level AI literacy as a missing governance capability: A pilot study of boards and executives. *Frontiers in Artificial Intelligence, 9*. https://doi.org/10.3389/frai.2026.1872783

van Giffen, B. i Ludwig, H. (2023). How boards of directors govern artificial intelligence. *MIS Quarterly Executive, 22(4)*, 251-272. https://doi.org/10.17705/2msqe.00085

Weill, P., Apel, T., Woerner, S. L. i Banner, J. S. (2019). It pays to have a digitally savvy board. *MIT Sloan Management Review, 60(3)*, 41-45.

Zhang, Z., Yoo, Y., Lyytinen, K. i Lindberg, A. (2021). The unknowability of autonomous tools and the liminal experience of their use. *Information Systems Research, 32(4)*, 1192-1213.

Zhao, J. (2024). Promoting more accountable AI in the boardroom through smart regulation. *Computer Law and Security Review, 52.* https://doi.org/10.1016/j.clsr.2024.105939

Zhao, J. i Gómez Fariñas, B. (2023). Artificial intelligence and sustainable decisions. *European Business Organization Law Review, 24(1)*, 1-39. https://doi.org/10.1007/s40804-022-00262-2

# WHAT ARE WE DEBATING? SUBSTITUTION OF JUDGMENT, THE RELATIONSHIP PARADIGM, AND OVERSIGHT CAPACITY AS THREE CENTRAL AXES OF DEBATE ON THE RELATIONSHIP BETWEEN BOARDS AND ARTIFICIAL INTELLIGENCE

***Abstract***

*The paper presents a critical narrative review and systematization of opposing theoretical, empirical, and normative positions in the scholarly literature on the relationship between boards and artificial intelligence. It proceeds from the research questions: which opposing positions exist in the literature, along which axes the debates unfold, and on which theoretical traditions they rest. Methodologically, it is based on a qualitative conceptual synthesis and theoretical analysis of relevant scientific and professional literature across corporate governance, corporate law, and artificial intelligence. Three mutually conditioned debates are systematized: on the substitution of human judgment (decision-making optimization versus the non-delegability of the fiduciary duties of care and loyalty), on the conceptualization of the relationship (artificial intelligence as a board resource versus an object of oversight and risk), and on the oversight capacity of non-executive entities under conditions of high technological complexity. From the hierarchy of these debates, two scenarios for the future of corporate governance are derived. The first is pathological, in which low digital literacy and algorithmic capture reduce the supervisory board to a rubber stamp. The second is the adaptive scenario, which restores oversight capacity through the development of evaluative literacy, technology subcommittees, and internal audit as the third line of defense. The originality of the paper is reflected in revealing three blind spots in the literature: the dominance of the one-tier governance model, with the neglect of the two-tier system characteristic of Croatia and continental Europe; the neglect of pathological phenomena such as morocracy; and the assumption of easy algorithmic verifiability. The main limitations concern the focus on selected representative literature in English and Croatian, and the lack of primary empirical validation of the derived scenarios.*

***Keywords:*** *artificial intelligence, corporate governance, supervisory board, fiduciary duties, internal audit.*

JEL klasifikacija: M10, M12, M14
Stručni rad

# SVRHOVITA ORGANIZACIJA: SPOJ STRATEGIJE, VODSTVA I OSOBNE SVRHE ZAPOSLENIKA

Nikolina Dreven*
Lorena Pikl**
Ivan Malbašić***

## SAŽETAK

Svrhovitost poslovanja nezaobilazna je tema suvremenog upravljanja organizacijama. Sve više menadžera, osobito u organizacijama koje jesu ili nastoje postati vodeće u svojoj djelatnosti, usmjerava pozornost na jasno definiranje razloga postojanja organizacije, doprinosa koji ona želi ostvariti te načina na koji se organizacijska svrha može povezati sa svakodnevnim radom zaposlenika. Međutim, svrha ne postaje stvarna samo zato što je zapisana u strateškim dokumentima – ona se prepoznaje u načinu na koji organizacija donosi odluke, kako menadžeri komuniciraju i žive organizacijske vrijednosti te u kojoj mjeri zaposlenici u vlastitom radu mogu pronaći osobni smisao. U ovom radu prikazano je kako se svrhovita organizacija može prepoznati kroz tri međusobno povezane dimenzije: strategiju vođenu svrhom, svrhovito vodstvo i osobnu svrhu zaposlenika. Rad

* Dr. sc. socio. Nikolina Dreven, Sveučilište u Zagrebu, Fakultet organizacije i informatike (e-mail: ndreven@foi.unizg.hr), korespondirajući autor.

** Dr. sc. socio. Lorena Pikl, Sveučilište u Zagrebu, Fakultet organizacije i informatike (e-mail: lpikl@foi.unizg.hr).

*** Izv. prof. dr. sc. Ivan Malbašić, Sveučilište u Zagrebu, Fakultet organizacije i informatike (e-mail: ivan.malbasic@foi.unizg.hr).

se temelji na podacima prikupljenima na uzorku od 620 zaposlenika iz 35 hrvatskih organizacija. Rezultati pokazuju relativno visoku razinu slaganja zaposlenika s tvrdnjama koje se odnose na sve tri dimenzije svrhovitosti, pri čemu je najviša prosječna vrijednost zabilježena kod osobne svrhe zaposlenika, zatim kod strategije vođene svrhom, dok je nešto niža prosječna vrijednost utvrđena kod svrhovitog vodstva. Dodatne analize pokazuju da su više prosječne vrijednosti kod osobne svrhe zabilježene kod starijih zaposlenika, dok su kod zaposlenika na menadžerskim pozicijama zabilježene više prosječne vrijednosti kod strategije vođene svrhom i svrhovitog vodstva u odnosu na izvršne i operativne zaposlenike. Rezultati upućuju na važnu praktičnu poruku: organizacije mogu imati zaposlenike koji u radu pronalaze osobni smisao, ali taj potencijal neće biti u potpunosti iskorišten ako se osobna svrha ne poveže s organizacijskom svrhom kroz jasnu strategiju i svrhovito vodstvo. Svrhovita organizacija stoga nije ona koja samo definira i deklarira svoju svrhu, nego ona koja tu svrhu uspijeva učiniti razumljivom, vidljivom i osobno relevantnom svojim zaposlenicima.

**Ključne riječi:** organizacijska svrha, strategija vođena svrhom, svrhovito vodstvo, osobna svrha zaposlenika, svrhovita organizacija.

# 1. UVOD

Suvremeno društvo obilježeno je visokom razinom materijalnog i tehnološkog razvoja, ali i stalnim promjenama koje snažno utječu na način života, rada i poslovanja. U takvom kontekstu sve se češće otvara pitanje smisla i svrhovitosti rada, odnosno načina na koji pojedinci razumiju vlastiti doprinos organizacijama i društvu. Literatura o smislenom radu pokazuje da rad za pojedinca ne predstavlja samo izvor materijalne sigurnosti nego i važan prostor oblikovanja identiteta, osobnog smisla i doprinosa nečemu širem od osobne koristi (Rosso i sur., 2010; Steger i sur., 2012).

Sličan izazov danas se javlja i pred organizacijama, kojima je potrebna šira perspektiva postojanja i jasnija svijest o svrsi koju žele ostvarivati kroz svoje poslovanje. Svrhovito poslovanje nadilazi ostvarivanje profita kao glavnog, a pogotovo kao jedinog razloga postojanja organizacije te uključuje odgovornost prema zaposlenicima, kupcima, zajednici, okolišu i društvu u cjelini. Hollensbe i sur. (2014) naglašavaju da organizacije trebaju promišljati svoju odgovornost kroz šire vrijednosti poput dostojanstva, solidarnosti, pluralnosti, supsidijarnosti, recipročnosti i održivosti.

U menadžerskoj literaturi organizacijska svrha često se koristi kako bi se naglasio pristup poslovanju koji nadilazi isključivu usmjerenost na interese vlasnika ili dioničara. George i sur. (2023) pritom upozoravaju da se pojam svrhe u menadžerskim istraživanjima koristi na različite načine i često nedovoljno precizno, zbog čega je važno jasno odrediti što se pod svrhom podrazumijeva. U skladu s takvim razumijevanjem, svrhovitu organizaciju (engl. *purpose-driven organization*) u ovom radu promatramo kao organizaciju u kojoj svrha nije samo formalna izjava, nego je ugrađena u strategiju, vidljiva u ponašanju vodstva i povezana s osobnim doživljajem smisla rada zaposlenika. Takvo razumijevanje oslanja se na radove koji naglašavaju da organizacijska svrha treba biti poznata zaposlenicima te internalizirana i povezana s konkretnim doprinosom svakodnevnom radu organizacije.

Lleó i sur. (2021) svrhu promatraju kroz tri dimenzije implementacije: znanje o svrsi, internalizaciju svrhe i doprinos svrsi. Prema njihovu pristupu, učinkovita implementacija svrhe zahtijeva intenzivan i uravnotežen razvoj svih triju dimenzija. Drugim riječima, svrha ne može ostati samo na razini formalnog znanja o tome što organizacija zastupa, nego treba biti osobno prihvaćena i povezana s konkretnim doprinosom zaposlenika svakodnevnom radu organizacije. Slično tome, važan teorijski oslonac predstavlja Model snage svrhe (engl. *Purpose Strength Model*), prema kojem relevantna organizacijska svrha može biti temelj organizacijskog identiteta i davati značenje svakodnevnom djelovanju organizacije. Model naglašava razvoj zajedničke svrhe, odnosno važnost toga da svrha ne ostane samo formalno definirana, nego da bude dijeljena, prepoznata i (o)življena među zaposlenicima (Chinchilla i sur., 2019; Lleó i sur., 2019).

Iz navedenog proizlazi da se svrhovita organizacija ne može razumjeti samo kroz postojanje izjave o svrsi i/ili misiji ili iz strateških dokumenata. Za njezino stvarno oblikovanje potrebno je razumjeti kako se svrha ugrađuje u strateško usmjerenje organizacije, kako se prenosi kroz vodstvo te kako se povezuje s osobnim doživljajem smisla rada zaposlenika. Upravo zato u ovom radu polazimo od tri međusobno povezane dimenzije svrhovitosti: strategije vođene svrhom, svrhovitog vodstva i osobne svrhe zaposlenika.

Cilj je ovog rada prikazati kako se svrhovita organizacija može prepoznati kroz naprijed navedene tri dimenzije svrhovitosti te ponuditi uvid u to kako zaposlenici doživljavaju navedene dimenzije u hrvatskim organizacijama. Pritom se ne nastoji dokazivati uzročno-posljedične odnose, nego prikazati

deskriptivnu sliku svrhovitosti u organizacijskom kontekstu. Takav pristup omogućuje bolje razumijevanje područja u kojima se svrha već prepoznaje kao važan dio organizacijskog života, a u kojima postoji prostor za njezino dodatno jačanje, osobito kroz svakodnevno djelovanje menadžera i povezivanje organizacijske svrhe s osobnim smislom rada zaposlenika.

## 2. SVRHOVITE ORGANIZACIJE U SUVREMENOM POSLOVNOM OKRUŽENJU

Organizacijska svrha najjednostavnije se može razumjeti kao odgovor na pitanje zašto organizacija postoji. Ipak, u suvremenom menadžmentu taj odgovor nije samo komunikacijsko ili marketinško pitanje, nego pitanje strategije, vodstva, identiteta i odnosa sa zaposlenicima. Van Ingen i sur. (2021) definiraju organizacijsku svrhu kao razlog postojanja organizacije obilježen značenjem, aspiracijom, usmjerenjem, ujedinjavanjem i motivacijom. Takvo razumijevanje pokazuje da svrha ima ulogu organizacijskog orijentira: ona objašnjava što organizacija želi ostvariti, zašto je njezin rad važan i kako može povezati različite dionike oko zajedničkog smjera.

Svrhovite organizacije nastaju onda kada organizacijska svrha nije samo formalno definirana, nego je ugrađena u način na koji organizacija promišlja svoje ciljeve, donosi odluke i oblikuje odnose sa zaposlenicima i drugim dionicima. Drugim riječima, svrha u takvim organizacijama nije samo izjava o namjeri, nego temelj za strateško usmjerenje, svakodnevno vodstvo i razumijevanje doprinosa zaposlenika. U uvjetima brzih promjena, globalne konkurentnosti, tržišne neizvjesnosti i rastućih očekivanja zaposlenika, kupaca i zajednice, važnost svrhovitih organizacija postaje sve izraženija.

Svrhovite organizacije ne postoje samo radi ostvarivanja profita. Njihova svrha proizlazi iz jasne namjere stvaranja pozitivnog utjecaja na različite dionike uključene u poslovanje, kao i na društvo u cjelini. To zahtijeva promjenu paradigme u razumijevanju organizacijske uspješnosti: profit ostaje važan, ali nije jedini kriterij uspjeha. Svrhovita organizacija uključuje brigu za zaposlenike, kupce, okoliš i društvo te nastoji stvarati održivu vrijednost za sve dionike, a ne samo za dioničare (Jordi, 2010).

**Slika 1. Od održivosti poslovanja prema svrhovitoj organizaciji**

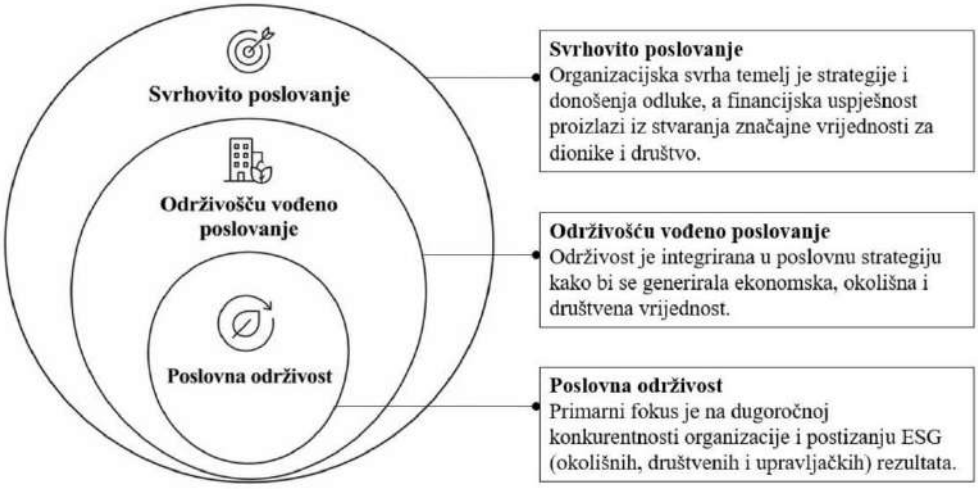


Izvor: izrada autora.

Slika 1. prikazuje odnos između poslovne održivosti, poslovanja vođenog održivošću i svrhovitog poslovanja. Poslovna održivost primarno se odnosi na dugoročnu konkurentnost organizacije i pokazatelje okolišnog, društvenog i upravljačkog djelovanja. Poslovanje vođeno održivošću uključuje ugradnju načela održivosti u poslovnu strategiju radi stvaranja ekonomske, okolišne i društvene vrijednosti. Svrhovito poslovanje ide korak dalje jer organizacijsku svrhu postavlja kao temelj strategije i donošenja odluka, pri čemu se financijska uspješnost promatra kao posljedica stvaranja smislene vrijednosti za dionike i društvo.

U tom smislu, svrhovito poslovanje može se promatrati kao način djelovanja svrhovite organizacije. Ono ne zamjenjuje održivost, nego joj daje dublji organizacijski temelj. Organizacija može provoditi održive prakse, ali svrhovita postaje tek onda kada je jasno zašto te prakse postoje, kako su povezane s njezinim identitetom i kako zaposlenici u njima mogu prepoznati vlastiti doprinos. Drugim riječima, svrha ne bi trebala biti samo poruka prema vanjskom okruženju, nego unutarnji organizacijski orijentir koji povezuje strategiju, vodstvo i svakodnevni rad zaposlenika.

Važan doprinos razumijevanju svrhovitih organizacija daju Almandoz i Rey (2026), koji naglašavaju da je definiranje organizacijske svrhe tek početna točka, dok je stvarni izazov njezina svakodnevna primjena. Prema njima,

svrha nije slogan, nego strateška i kulturna snaga koja oblikuje način na koji organizacije djeluju i utječu na društvo. U tom okviru svrha se ostvaruje kroz tri povezane dimenzije: jasnoću svrhe, emocionalnu povezanost sa svrhom i praktičnu provedbu svrhe. Takvo razumijevanje posebno je važno jer pokazuje da svrhovita organizacija ne nastaje samim definiranjem svrhe, nego njezinim prevođenjem u strategiju, vodstvo, organizacijske sustave i svakodnevna ponašanja.

Za razvoj svrhovitih organizacija osobito je važno povezivanje organizacijske i osobne svrhe. Kada zaposlenici mogu povezati vlastitu svrhu s organizacijskom svrhom, njihov rad može postati više od izvršavanja zadataka: on postaje prostor osobnog doprinosa, smisla i identifikacije s organizacijom. U tom slučaju svrha nije samo nešto što organizacija komunicira, nego nešto što zaposlenici mogu razumjeti, prihvatiti i povezati s vlastitim radom.

Slika 2. prikazuje da svrhovita organizacija ne nastaje samo postojanjem organizacijske svrhe, nego njezinim povezivanjem s osobnim svrhama zaposlenika. Kada osobna svrha zaposlenika i organizacijska svrha ostaju odvojene, svrha može biti formalno definirana, ali nedovoljno osobno relevantna. Kada se te dvije razine povežu, nastaje sinergija svrhe, odnosno prostor u kojem zaposlenici mogu prepoznati kako njihov osobni doprinos sudjeluje u ostvarivanju šire organizacijske svrhe.

**Slika 2. Povezivanje osobne i organizacijske svrhe**

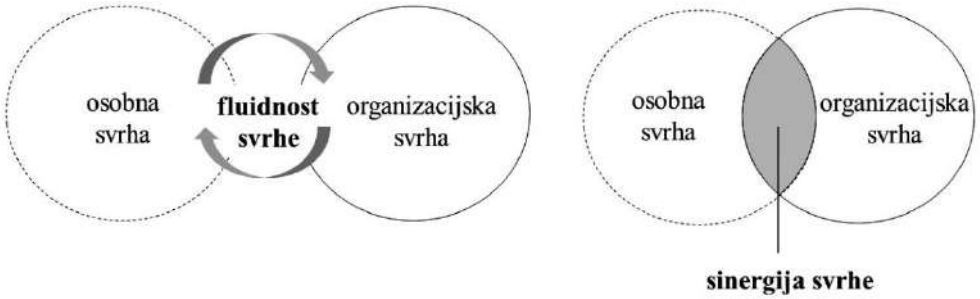


Izvor: Malbašić i Rey (2019).

Rey i sur. (2019) naglašavaju da ispunjenje osobne svrhe unutar organizacijske svrhe predstavlja srž svrhovite organizacije, pri čemu svaki pojedinac treba

moći prepoznati vlastiti doprinos zajedničkoj svrsi. S time je povezan i pojam zajedničke svrhe (engl. *shared purpose*). Zajednička svrha ne znači da svi zaposlenici imaju iste osobne ciljeve ili vrijednosti, nego da mogu prepoznati kako njihovi različiti doprinosi sudjeluju u ostvarivanju šire organizacijske svrhe. Takvo razumijevanje svrhe važno je jer naglašava da svrha nije samo izjava o tome što organizacija želi biti, nego orijentir koji povezuje ljude, usmjerava odluke i daje smisao svakodnevnom radu.

## 3. STRATEGIJA VOĐENA SVRHOM, SVRHOVITO VODSTVO I OSOBNA SVRHA ZAPOSLENIKA

U ovom se radu svrhovita organizacija promatra kroz tri dimenzije svrhovitosti koje povezuju teorijski okvir svrhovitog poslovanja s iskustvom zaposlenika: strategiju vođenu svrhom, svrhovito vodstvo i osobnu svrhu zaposlenika.

*Strategija vođena svrhom* pokazuje u kojoj je mjeri svrha ugrađena u strateško usmjerenje organizacije, njezine ciljeve, prioritete i odluke. Ako je svrha dio strategije, zaposlenici lakše razumiju širu sliku vlastitog rada. Tada svakodnevni zadaci nisu samo operativne obveze, nego dio većeg organizacijskog doprinosa. Strategija vođena svrhom ne znači da organizacija zanemaruje učinkovitost, tržišnu poziciju ili financijske rezultate. Naprotiv, ona znači da se poslovni ciljevi povezuju s jasnijim odgovorom na pitanje zašto organizacija postoji i kakvu vrijednost želi stvarati. U tom kontekstu, strategiju vođenu svrhom promatramo kroz percepciju zaposlenika da organizacija ima jasan smjer povezan sa svrhom, odnosno da svrha nije samo deklarativna, nego dio načina na koji organizacija promišlja svoj razvoj. Stoga je strategija vođena svrhom bliska dimenziji jasnoće svrhe koju opisuju Almandoz i Rey (2026), navodeći da svrha treba biti jasno definirana i komunicirana kao racionalni temelj strategije i donošenja odluka. Dobro oblikovana svrha donosi jasnoću, usklađuje timove i jača organizacijski identitet.

*Svrhovito vodstvo* odnosi se na ulogu menadžera u komuniciranju, tumačenju i provođenju organizacijske svrhe. Menadžeri imaju ključnu ulogu u tome hoće li organizacijska svrha ostati formalna izjava ili će postati dio svakodnevnog rada. Svrha se zaposlenicima u pravilu ne prenosi kroz strateške dokumente, već ponajviše kroz ponašanje nadređenih – njihovu svakodnevnu komunikaciju, način donošenja odluka i objašnjenje zašto je

određeni posao važan. Almandoz i Rey (2026) ističu kako svrhovito vodstvo nije jednokratna deklaracija, već kontinuirani proces koji zahtijeva usklađivanje strategije, kulture i svakodnevnog djelovanja. Prema njima, lideri trebaju ugraditi svrhu u samo tkivo organizacije, pretvarajući aspiracije u stvarnost. Pritom svrha treba biti operacionalizirana, odnosno ugrađena u ponašanja, odluke, svakodnevne aktivnosti, sustave, pokazatelje uspješnosti, poticaje i menadžerske prakse. Svrhovito vodstvo može se razumjeti i kao sposobnost povezivanja unutarnje i vanjske perspektive organizacijske svrhe. S jedne strane, menadžeri trebaju povezati svrhu s poviješću, vrijednostima i identitetom organizacije te među zaposlenicima razvijati autentičnost, ponos i zajedničku kulturu. S druge strane, trebaju razumjeti očekivanja društva i dionika te organizaciju usmjeravati prema širem društvenom doprinosu. Almandoz i Rey (2026) zato ističu da autentično svrhovito vodstvo ne počinje vanjskim pritiscima ili regulatornim zahtjevima, već unutarnjim uvjerenjima lidera koja se dodatno oblikuju kroz odgovor na potrebe društva i okruženja.

*Osobna svrha zaposlenika* odnosi se na doživljaj da je vlastiti rad smislen, vrijedan i povezan s onim što je osobi važno. Ova dimenzija posebno je važna jer organizacija ne može biti doista svrhovita ako zaposlenici u svom radu ne mogu prepoznati osobni smisao. Literatura o smislenom radu pokazuje da zaposlenici smisao rada oblikuju iz različitih izvora. Rosso i sur. (2010) u svojem teorijskom pregledu ističu da se značenje rada može promatrati kroz izvore smisla i mehanizme putem kojih rad postaje smislen. Steger i sur. (2012) smisleni rad opisuju kao subjektivno iskustvo koje uključuje pozitivno značenje rada, doživljaj da rad pomaže osobi stvarati smisao u životu te percepciju da rad doprinosi nečem većem od osobne koristi. Almandoz i Rey (2026) naglašavaju da svrha mora biti internalizirana, odnosno ne samo intelektualno shvaćena, nego i emocionalno doživljena. Kada zaposlenici vide kako njihov rad poboljšava živote drugih, njihova angažiranost se produbljuje, a motivacija postaje više intrinzična. Drugim riječima, osobna svrha zaposlenika važna je zato što povezuje svakodnevni rad s osobnim vrijednostima, smislom i doživljajem doprinosa. Međutim, osobna svrha zaposlenika sama po sebi nije dovoljna za razvoj svrhovite organizacije. Zaposlenik može osobno doživljavati svoj rad smislenim, ali ako se taj smisao ne povezuje s organizacijskom svrhom, onda ostaje primarno individualna kategorija. Svrhovita organizacija nastaje onda kada se osobni smisao rada poveže s organizacijskim smjerom, svrhovitim vodstvom i zajedničkim doprinosom.

# 4. REZULTATI ISTRAŽIVANJA O SVRHOVITOM POSLOVANJU U HRVATSKOM POSLOVNOM KONTEKSTU

U istraživanju je sudjelovalo 35 organizacija, odabranih namjernim uzorkom prema relevantnosti za predmet istraživanja te dostupnosti i spremnosti na sudjelovanje, a jedan od kriterija odabira organizacije bio je da mora ima najmanje 20 zaposlenika. Istraživanje je provedeno online anketnim upitnikom. Organizacije obuhvaćene istraživanjem djeluju, među ostalim, u području prerađivačke i prehrambene industrije, informacijskih tehnologija i telekomunikacija, trgovine, prometa i logistike, energetike, financijskih i osiguravateljskih usluga, građevinarstva, turizma, zdravstva i obrazovanja. Među organizacijama obuhvaćenima istraživanjem bilo je pet malih, 13 srednjih i 15 velikih organizacija te dvije javne ustanove.

Istraživanjem su ispitane tri dimenzije svrhovitosti: strategija vođena svrhom (tri čestice; Marimon i sur., 2016), svrhovito vodstvo (četiri čestice; Marimon i sur., 2016) i osobna svrha zaposlenika (tri čestice; Steger i sur., 2006). Odgovori su prikupljeni na Likertovoj ljestvici od 1 do 5, pri čemu veće vrijednosti označavaju višu razinu slaganja s tvrdnjama koje se odnose na pojedinu dimenziju. U ovom radu prikazani su osnovni deskriptivni pokazatelji, odnosno aritmetičke sredine i medijani. Budući da je riječ o stručnom radu, rezultati nisu prikazani s ciljem dokazivanja uzročno-posljedičnih odnosa, nego kao praktičan uvid u izraženost različitih aspekata svrhovitosti među zaposlenicima.

Rezultati u Tablici 1. pokazuju da zaposlenici iskazuju relativno visoku razinu slaganja s tvrdnjama koje se odnose na sve tri dimenzije svrhovitosti. Najviša prosječna vrijednost zabilježena je kod osobne svrhe zaposlenika ($M = 3.88$), zatim kod strategije vođene svrhom ($M = 3.80$), dok je nešto niža kod svrhovitog vodstva ($M = 3.74$). Medijan za sve tri dimenzije iznosi 4.00, što dodatno potvrđuje relativno visoku razinu slaganja s pripadajućim tvrdnjama. U praksi to znači da zaposlenici uglavnom prepoznaju smisao vlastitog rada i svrhu organizacije, dok nešto niža prosječna vrijednost kod svrhovitog vodstva upućuje na prostor za snažnije komuniciranje i povezivanje svrhe sa svakodnevnim radom zaposlenika.

**Tablica 1. Osnovni deskriptivni pokazatelji po dimenzijama svrhovitosti**

| Dimenzija | N | M | Medijan |
|---|---|---|---|
| Strategija vođena svrhom | 620 | 3.80 | 4.00 |
| Svrhovito vodstvo | 620 | 3.74 | 4.00 |
| Osobna svrha | 620 | 3.88 | 4.00 |

Izvor: izrada autora.

Analiza prema spolu (Slika 3.) pokazuje da žene iskazuju nešto više prosječne vrijednosti za sve tri dimenzije svrhovitosti u odnosu na muškarce. Kod žena prosječne vrijednosti iznose 3.85 kod strategije vođene svrhom, 3.79 kod svrhovitog vodstva i 3.92 kod osobne svrhe, dok kod muškaraca iznose 3.74, 3.68 i 3.83. U praksi to znači da žene nešto jasnije prepoznaju svrhu u vlastitom radu te njezinu prisutnost u strategiji i ponašanju vodstva, iako su razlike između žena i muškaraca relativno male.

**Slika 3. Dimenzije svrhovitosti prema spolu**

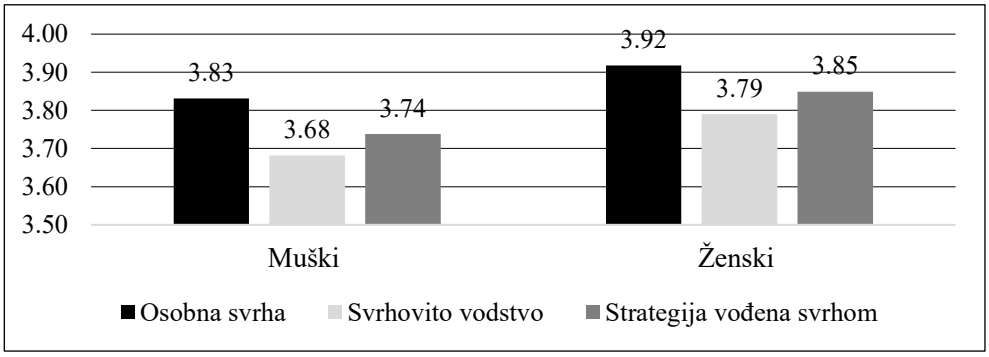


Izvor: izrada autora.

Analiza prema dobi (Slika 4.) pokazuje zanimljiv obrazac. Kod najmlađih zaposlenika, u dobi od 35 godina ili manje, zabilježene su najviše prosječne vrijednosti kod strategije vođene svrhom (M = 3.88) i svrhovitog vodstva (M = 3.88), dok je kod osobne svrhe utvrđena najniža prosječna vrijednost (M = 3.71). Nasuprot tome, prosječna vrijednost kod osobne svrhe raste s dobi te je najviša kod zaposlenika u dobi od 56 godina i više (M = 4.04). Ovaj nalaz može upućivati na to da se doživljaj osobnog smisla rada povećava s radnim

i životnim iskustvom, dok mlađi zaposlenici jasnije prepoznaju svrhu u strategiji i ponašanju vodstva.

**Slika 4. Dimenzije svrhovitosti prema dobi**

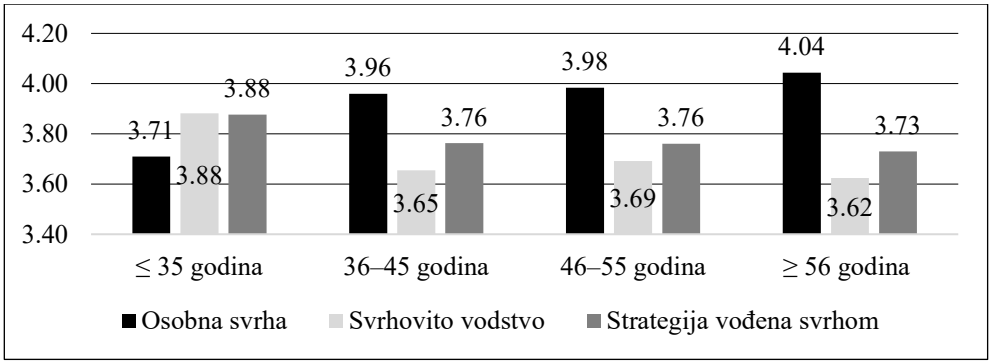


Izvor: izrada autora.

Analiza prema obrazovanju (Slika 5.) pokazuje da su razlike među obrazovnim skupinama ispitanika uglavnom umjerene te ih je potrebno interpretirati oprezno zbog vrlo nejednake veličine skupina. Primjerice, skupina zaposlenika s osnovnom školom ili nižim obrazovanjem obuhvaća samo sedam ispitanika, dok skupina s magisterijem ili doktoratom znanosti obuhvaća samo tri ispitanika. Deskriptivno se može uočiti da su kod zaposlenika s VŠS-om, stručnim studijem ili prvim stupnjem fakulteta zabilježene relativno visoke prosječne vrijednosti kod strategije vođene svrhom (M = 3.98) i svrhovitog vodstva (M = 3.96), dok je najviša prosječna vrijednost kod osobne svrhe utvrđena u vrlo maloj skupini zaposlenika s magisterijem ili doktoratom znanosti (M = 4.56). U praksi to upućuje na moguće razlike u doživljaju strategije vođene svrhom, svrhovitog vodstva i osobne svrhe među zaposlenicima različitog obrazovanja, ali zbog malog broja ispitanika u pojedinim skupinama takve nalaze treba tumačiti oprezno i ne generalizirati ih na širu populaciju.

**Slika 5. Dimenzije svrhovitosti prema obrazovanju**

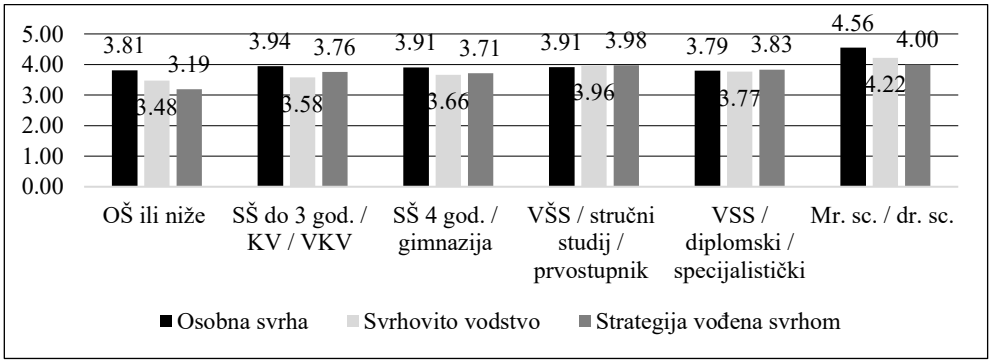


Izvor: izrada autora.

Zanimljivi nalazi uočeni su i kod analize prema radnom mjestu. Kod izvršnih i operativnih zaposlenika zabilježene su najniže prosječne vrijednosti kod strategije vođene svrhom (M = 3.67) i svrhovitog vodstva (M = 3.55), dok su prosječne vrijednosti više kod stručnih i administrativnih zaposlenika, nižeg i srednjeg menadžmenta te vrhovnog menadžmenta. U praksi to znači da zaposlenici na višim hijerarhijskim razinama jasnije prepoznaju svrhu u strategiji i ponašanju vodstva. Najviše prosječne vrijednosti zabilježene su kod vrhovnog menadžmenta, posebno kod strategije vođene svrhom (M = 4.24) i svrhovitog vodstva (M = 4.19). Ovakav nalaz može upućivati na to da su zaposlenici na menadžerskim pozicijama bliže strateškim informacijama, procesima odlučivanja i komunikaciji organizacijske svrhe, dok izvršni i operativni zaposlenici svrhu nešto slabije prepoznaju u svakodnevnom radu. Za organizacije je to važna praktična poruka: svrha ne bi smjela ostati samo na razini menadžmenta, nego treba biti jasnije prevedena u jezik, zadatke i iskustvo svih zaposlenika.

**Slika 6. Dimenzije svrhovitosti prema radnom mjestu**

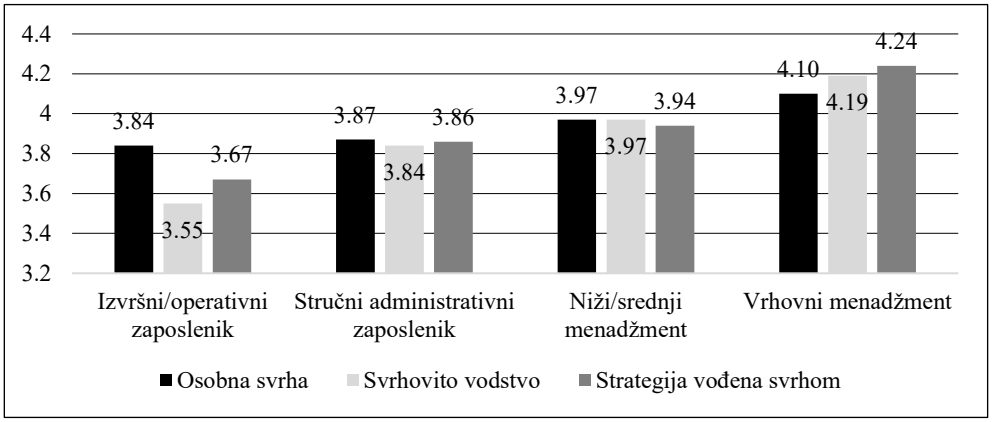


Izvor: izrada autora.

# 5. RASPRAVA I PRAKTIČNE PREPORUKE ZA ORGANIZACIJE

Rezultati pokazuju da zaposlenici iskazuju relativno visoku razinu slaganja s tvrdnjama koje se odnose na sve tri analizirane dimenzije svrhovitosti, što upućuje na to da u značajnoj mjeri prepoznaju osobni smisao vlastitog rada te svrhu u strategiji i ponašanju vodstva. Najviša prosječna vrijednost zabilježena je kod osobne svrhe zaposlenika, zatim kod strategije vođene svrhom, dok je nešto niža prosječna vrijednost utvrđena kod svrhovitog vodstva. Ovakav rezultat upućuje na to da zaposlenici u velikoj mjeri pronalaze osobni smisao u radu i prepoznaju svrhu u strategiji organizacije, ali da postoji prostor za jačanje uloge menadžera u svakodnevnom povezivanju tih dviju razina. Ovaj nalaz može se povezati s tvrdnjom Almandoza i Reya (2026) da definiranje svrhe nije dovoljno jer je stvarni izazov njezina svakodnevna primjena. Nešto niža prosječna vrijednost kod svrhovitog vodstva može značiti da svrha postoji kao organizacijska ideja i osobni doživljaj smisla, ali da njezino svakodnevno prevođenje kroz ponašanje menadžera, organizacijske sustave i konkretne prakse još uvijek predstavlja prostor za razvoj. Ovaj je nalaz važan i u kontekstu povezivanja osobne i organizacijske svrhe – ako zaposlenici već imaju razvijen osjećaj osobne svrhe, organizacije imaju vrijedan temelj na kojem mogu graditi. Međutim, taj se potencijal neće u potpunosti ostvariti ako organizacijska svrha ostane samo na razini strateških dokumenata ili formalnih poruka.

Potrebni su menadžeri koji će svrhu približiti zaposlenicima, povezati je s konkretnim zadacima i pokazati kako se ona ostvaruje kroz svakodnevne odluke i ponašanja.

Dodatni nalazi potvrđuju važnost komunikacije svrhe prema različitim skupinama zaposlenika. Posebno je važno obratiti pozornost na izvršne i operativne zaposlenike, kod kojih su zabilježene niže prosječne vrijednosti kod strategije vođene svrhom i svrhovitog vodstva. U praksi to može značiti da zaposlenici na tim radnim mjestima slabije prepoznaju povezanost organizacijske svrhe sa strategijom i ponašanjem vodstva, odnosno da im se svrha prenosi manje jasno ili konkretno nego zaposlenicima na menadžerskim pozicijama. Rezultati prema dobi također nude zanimljiv stručni uvid. Kod mlađih zaposlenika zabilježene su najviše prosječne vrijednosti kod strategije vođene svrhom i svrhovitog vodstva, ali i najniža prosječna vrijednost kod osobne svrhe. S druge strane, prosječna vrijednost kod osobne svrhe raste s dobi. To može upućivati na to da se osobni doživljaj smisla rada oblikuje kroz radno i životno iskustvo, dok su kod mlađih zaposlenika zabilježene više prosječne vrijednosti kod strategije vođene svrhom i svrhovitog vodstva.

Ukupno gledano, rezultati upućuju na to da svrhovita organizacija ne nastaje samo definiranjem svrhe, nego njezinim povezivanjem sa strategijom, vodstvom i osobnim smislom rada zaposlenika. Ako jedna od tih dimenzija izostane, svrha može ostati djelomična: strateški definirana, ali nedovoljno (o)življena; osobno važna, ali nedovoljno povezana s organizacijom; ili komunicirana kroz vodstvo, ali bez jasnog strateškog uporišta.

Na temelju prikazanih rezultata mogu se izdvojiti četiri praktične preporuke za organizacije koje žele razvijati svrhovitost. Prvo, organizacije trebaju jasno povezati svrhu sa strategijom. Svrha treba biti vidljiva u ciljevima, prioritetima i odlukama, a ne samo u komunikacijskim materijalima. Svrha koja je jasno definirana i povezana sa strategijom zaposlenicima olakšava razumijevanje smjera organizacije i vlastitog doprinosa tom smjeru. Drugo, potrebno je razvijati svrhovito vodstvo. Menadžeri trebaju znati objasniti zaposlenicima zašto je njihov rad važan, kako doprinosi organizacijskim ciljevima i na koji način organizacija stvara vrijednost za širu zajednicu. Budući da je kod svrhovitog vodstva zabilježena nešto niža prosječna vrijednost u odnosu na osobnu svrhu i strategiju vođenu svrhom, ova dimenzija predstavlja posebno važno područje za razvoj. Treće, organizacije trebaju aktivno promišljati o osobnoj svrsi zaposlenika. To znači stvarati radno okruženje u kojem zaposlenici mogu prepoznati smisao vlastitog rada,

osjećati da njihov doprinos ima vrijednost i povezati vlastite vrijednosti s organizacijskom svrhom. Četvrto, svrhu je potrebno približiti svim hijerarhijskim razinama. Više prosječne vrijednosti kod strategije vođene svrhom i svrhovitog vodstva kod zaposlenika na menadžerskim pozicijama u odnosu na izvršne i operativne zaposlenike upućuju na to da menadžeri jasnije prepoznaju svrhu u strategiji i ponašanju vodstva. To znači da organizacije trebaju dodatno raditi na tome da svrha ne ostane samo tema strateških sastanaka i menadžerske komunikacije, nego da bude jasna i zaposlenicima koji svakodnevno provode operativne zadatke.

**Slika 7. Kako nastaje svrhovita organizacija?**

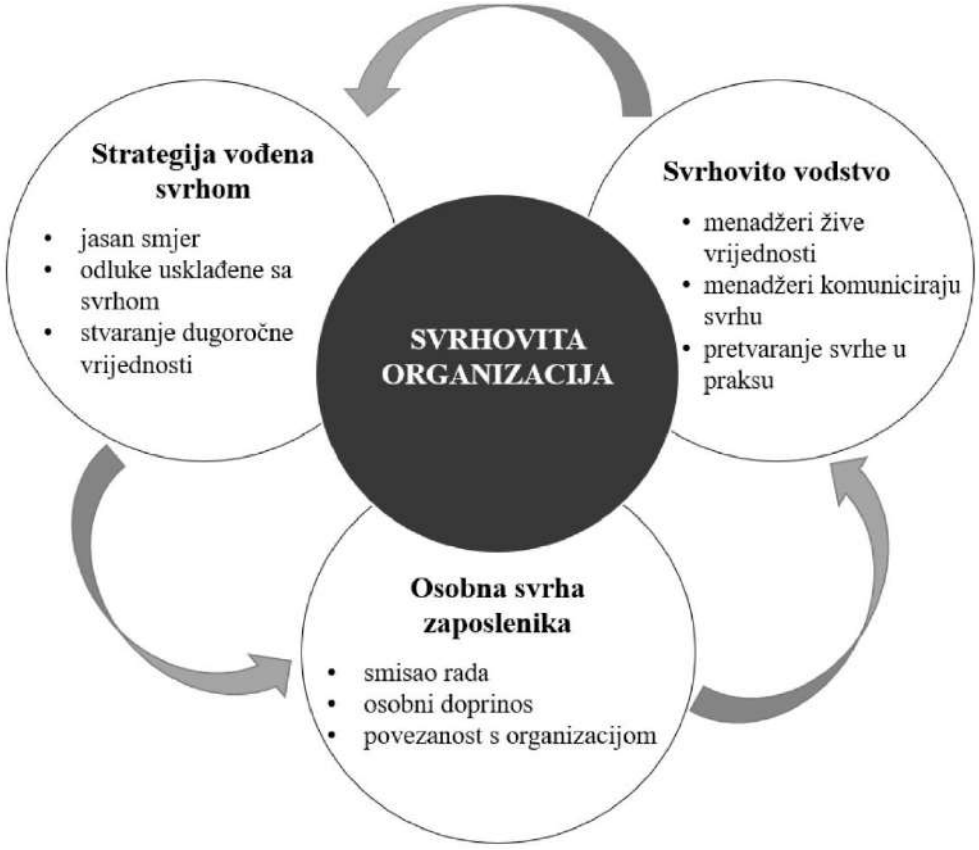


Izvor: izrada autora.

Slika 7. sažima središnju poruku ovog rada: svrhovita organizacija nastaje povezivanjem strategije vođene svrhom, svrhovitog vodstva i osobne svrhe zaposlenika. Strategija vođena svrhom daje organizaciji jasan smjer, usklađuje odluke sa svrhom i usmjerava stvaranje dugoročne vrijednosti. Svrhovito vodstvo omogućuje da menadžeri žive vrijednosti, komuniciraju svrhu i pretvaraju je u praksu. Osobna svrha zaposlenika povezuje smisao rada, osobni doprinos i povezanost s organizacijom. Upravo u tom spoju strategije vođene svrhom, svrhovitog vodstva i osobne svrhe zaposlenika nalazi se praktična snaga svrhovite organizacije. Strategija daje smjer, vodstvo prevodi svrhu u svakodnevnu praksu, a osobna svrha zaposlenika daje smisao individualnom doprinosu. Kada su te tri dimenzije povezane, svrha prestaje biti apstraktna izjava i postaje dio načina na koji organizacija svakodnevno djeluje.

## ZAHVALE

Ovaj je rad financiran sredstvima Europske unije kroz instrument NextGenerationEU u okviru projekta broj 2025-657.

# LITERATURA

Almandoz, J. i Rey, C. (2026). Leading with Purpose: Uniting Inner Conviction and Societal Demands. *The European Business Review*, str. 18–23.

Chinchilla, N., Lleó, Á., Rey, C., Alloza, Á. i Pitta, N. (2019). *Purpose Strength Model: Towards a Shared Purpose*. https://doi.org/https://dx.doi.org/10.15581/018.ST-524-E

George, G., Haas, M. R., McGahan, A. M., Schillebeeckx, S. J. D. i Tracey, P. (2023). Purpose in the For-Profit Firm: A Review and Framework for Management Research. *Journal of Management*, *49*(6), str. 1841–1869. https://doi.org/10.1177/01492063211006450

Hollensbe, E., Wookey, C., Hickey, L., George, G. i Nichols, C. V. (2014). Organizations with Purpose. *Academy of Management Journal*, *57*(5), str. 1227–1234. https://doi.org/10.5465/amj.2014.4005

Jordi, C. L. (2010). Rethinking the firm's mission and purpose. *European Management Review*, *7*(4), str. 195–204. https://doi.org/10.1057/emr.2010.11

Lleo, A., Bastons, M., Rey, C. i Ruiz-Perez, F. (2021). Purpose Implementation: Conceptualization and Measurement. *Sustainability*, *13*, 1921. https://doi.org/10.2139/ssrn.3630416

Lleo, A., Rey, C. i Chinchilla, N. (2019). Measuring the Purpose Strength. U C. Rey, M. Bastons i P. Sotok (Ur.), *Purpose-driven Organizations: Management Ideas for a Better World* (str. 119–130). Palgrave Macmillan.

Malbašić, I. i Rey, C. (2019). Harmonization of Personal and Organizational Purpose. U C. Rey, M. Bastons i P. Sotok (Ur.) *Purpose-Driven Organizations: Management Ideas for a Better World* (str. 17–27). Palgrave Macmillan.

Marimon, F., Mas-Machuca, M. i Rey, C. (2016). Assessing the internalization of the mission. *Industrial Management and Data Systems*, *116*(1), str. 170–187. https://doi.org/10.1108/IMDS-04-2015-0144

Rey, C., Velasco, J. S. C. i Almandoz, J. (2019). The New Logic of Purpose Within the Organization. U C. Rey, M. Bastons i P. Sotok (Ur.), *Purpose-driven Organizations: Management Ideas for a Better World* (str. 3–15). Palgrave Macmillan.

Rosso, B. D., Dekas, K. H. i Wrzesniewski, A. (2010). On the meaning of work: A theoretical integration and review. *Research in Organizational Behavior*, *30*, str. 91–127. https://doi.org/10.1016/j.riob.2010.09.001

Steger, M. F., Dik, B. J. i Duffy, R. D. (2012). Measuring Meaningful Work: The Work and Meaning Inventory (WAMI). *Journal of Career Assessment*, *20*(3), str. 322–337. https://doi.org/10.1177/1069072711436160

Steger, M. F., Frazier, P., Oishi, S. i Kaler, M. (2006). The Meaning in Life Questionnaire: Assessing the Presence of and Search for Meaning in Life. *Journal of Counseling Psychology*, *53*(1), str. 80–93. https://doi.org/10.1037/0022-0167.53.1.80

van Ingen, R., Peters, P., De Ruiter, M. i Robben, H. (2021). Exploring the Meaning of Organizational Purpose at a New Dawn: The Development of a Conceptual Model Through Expert Interviews. *Frontiers in Psychology*, *12*, str. 1–17. https://doi.org/10.3389/fpsyg.2021.675543

# THE PURPOSE-DRIVEN ORGANIZATION: INTEGRATING STRATEGY, LEADERSHIP, AND EMPLOYEES' PERSONAL PURPOSE

***Abstract***

*Purpose-driven business has become an essential topic in contemporary organizational management. An increasing number of managers, particularly in organizations that are or aspire to become leaders in their industries, are focusing on clearly defining why their organizations exist, the contribution they aim to make, and how organizational purpose can be connected to employees' everyday work. However, purpose does not become meaningful simply because it is articulated in strategic documents. Rather, it is reflected in the way an organization makes decisions, how managers communicate and embody organizational values, and the extent to which employees are able to find personal meaning in their work. This paper examines how a purpose-driven organization can be understood through three interrelated dimensions: purpose-driven strategy, purpose-driven leadership, and employees' personal purpose. The paper is based on data collected from a sample of 620 employees across 35 Croatian organizations. The results indicate a relatively high level of employee agreement with statements related to all three dimensions of purpose. The highest mean value was recorded for employees' personal purpose, followed by purpose-driven strategy, while a somewhat lower mean value was found for purpose-driven leadership. Additional analyses show that higher mean values of personal purpose were observed among older employees, whereas higher mean values for purpose-driven strategy and purpose-driven leadership were recorded among managers than among executive and operational employees. The findings convey an important practical implication: organizations may have employees who find personal meaning in their work, but this potential cannot be fully realized unless employees' personal purpose is aligned with the organization's purpose through a clear strategy and purpose-driven leadership. A purpose-driven organization is therefore not merely one that clearly defines and declares its purpose, but one that succeeds in making that purpose understandable, visible, and personally relevant to its employees.*

***Keywords:*** *organizational purpose, purpose-driven strategy, purpose-driven leadership, employees' personal purpose, purpose-driven organization.*

JEL klasifikacija: G34, H83, L32
Stručni rad

# UPRAVLJAČKA ODGOVORNOST U TRGOVAČKIM DRUŠTVIMA U VLASNIŠTVU JEDINICA LOKALNE SAMOUPRAVE U REPUBLICI HRVATSKOJ: ANALIZA PRIMJENOM PRILAGOĐENOG RELOF INDEKSA

Marko Mikšić*

## SAŽETAK

Ovaj rad analizira kvalitetu praksi upravljačke odgovornosti u trgovačkim društvima u vlasništvu jedinica lokalne samouprave u Republici Hrvatskoj. Javna poduzeća imaju važnu gospodarsku i društvenu ulogu jer upravljaju značajnom javnom imovinom, zapošljavaju velik broj ljudi i pružaju usluge od neposredne važnosti za građane. Odluke menadžmenta utječu ne samo na poslovne rezultate poduzeća nego i na dostupnost i kvalitetu javnih usluga, socijalnu stabilnost te razvoj lokalnih zajednica i države. Stoga se od javnih poduzeća očekuje viša razina upravljačke odgovornosti nego u privatnom sektoru. Cilj rada jest utvrditi ključne prednosti i nedostatke postojećih praksi upravljačke odgovornosti.

* Marko Mikšić, spec. oec., samostalni istraživač (e-mail: miksic.marko@gmail.com).

Empirijsko istraživanje provedeno je na uzorku od 33 trgovačka društva primjenom prilagođenog RELOF indeksa. Izvorni indeks prilagođen je predmetu istraživanja izmjenom pondera njegovih sastavnica i usklađivanjem indikatora s hrvatskim pravnim i institucionalnim okvirom. Primarni podaci prikupljeni su upitnicima izrađenima prema metodologiji kartice postignuća.

Rezultati pokazuju da prosječna vrijednost indeksa upravljačke odgovornosti iznosi 45,80 %. Nijedno poduzeće nije ostvarilo najvišu razinu upravljačke odgovornosti, dok se svako treće nalazi ispod minimalno prihvatljivog praga. Uočena je značajna razlika između rezultata jedinica lokalne samouprave kao vlasnika, čiji prosječni indeks iznosi 28,90 %, i trgovačkih društava u njihovu vlasništvu, s prosječnim indeksom od 52,48 %. Takav jaz upućuje na nedovoljno aktivnu ulogu vlasnika i izostanak integrirane vlasničke politike. Usporedba sa Srbijom pokazuje blagu do umjerenu prednost Hrvatske, ali istodobno potvrđuje da formalno usvajanje normativnih standarda samo po sebi ne osigurava višu razinu upravljačke odgovornosti u praksi.

Ograničenja istraživanja proizlaze iz relativno malog uzorka, niske stope odaziva i moguće pristranosti odaziva, zbog čega rezultate treba tumačiti kao indikativne.

Doprinos rada očituje se u prilagodbi i primjeni strukturiranog indeksa koji, osim istraživačkog instrumenta, predstavlja i dijagnostički te upravljački alat. Njegova primjena omogućuje javnim poduzećima i njihovim vlasnicima objektivnu procjenu postojećih praksi upravljačke odgovornosti, usporedbu s drugim poduzećima te praćenje njihova razvoja tijekom vremena.

**Ključne riječi:** upravljačka odgovornost, korporativno upravljanje, javna poduzeća, jedinice lokalne samouprave, indeks upravljačke odgovornosti.

## 1. UVODNA RAZMATRANJA

Trgovačka društva u javnom vlasništvu imaju posebno mjesto u sustavu upravljanja javnim resursima jer istodobno djeluju kao poslovni subjekti i kao instrumenti kojima država ili lokalna zajednica osigurava usluge od neposrednog javnog interesa. Njihove odluke utječu na korištenje javne imovine, kvalitetu i dostupnost komunalnih i drugih usluga, zaposlenost te fiskalnu izloženost vlasnika. Zbog toga se kvaliteta njihova upravljanja ne može ocjenjivati samo kroz ostvareni financijski rezultat nego i kroz način na koji upravljačke strukture

polažu račune vlasniku, nadzornim tijelima i građanima (Organizacija za ekonomsku suradnju i razvoj [OECD], 2021, 2024).

Javna poduzeća suočavaju se sa specifičnim izazovima u području upravljačke odgovornosti, među kojima se ističu rizici od korupcije i sukoba interesa, manjak profesionalnih standarda, niska razina transparentnosti, ograničena operativna autonomija, izazovi u očuvanju tržišne konkurentnosti te nedovoljno razvijeni sustavi upravljanja rizicima (OECD, 2024).

Hrvatski kontekst dodatno je obilježen velikim brojem poduzeća na lokalnoj razini (Tipurić, Cindrić, Žuro i Idžojtić, 2026) i neujednačenim kapacitetima njihovih vlasnika, uprava i nadzornih odbora. Državni ured za reviziju (2023) i Ministarstvo pravosuđa i uprave RH (2020) ukazuju na potrebu jačanja nadzora, unutarnjih kontrola, transparentnosti i odgovornog upravljanja javnim poduzećima. Slične zahtjeve postavlja i Priručnik za primjenu smjernica OECD-a, primjenjiv na trgovačka društva u većinskom vlasništvu jedinica lokalne i područne samouprave (Ministarstvo pravosuđa, uprave i digitalne transformacije RH, 2024).

U takvom okruženju problem nije samo donošenje i postojanje pravila, nego njihova stvarna primjena. Formalno usvajanje procedura, kodeksa i podnošenje izvještaja ne znači nužno da vlasnik aktivno postavlja ciljeve, da nadzorni odbor stvarno prati rad poduzeća ili da se rezultati poslovanja sustavno vrednuju (OECD, 2020, 2024). Upravo je zato za procjenu upravljačke odgovornosti potreban instrument koji omogućuje usporedivo i ponovljivo mjerenje konkretnih praksi.

Predmet ovog rada jest analiza praksi upravljačke odgovornosti u trgovačkim društvima u vlasništvu jedinica lokalne samouprave (JLS) u Republici Hrvatskoj. Cilj rada jest utvrditi ključne prednosti i nedostatke tih praksi primjenom strukturiranog alata za njihovo mjerenje. Prilagodba RELOF indeksa hrvatskom pravnom i institucionalnom okviru te njegova primjena središnji su stručni doprinosi ovog rada.

## 2. POJMOVNO ODREĐENJE UPRAVLJAČKE ODGOVORNOSTI

Upravljačka odgovornost u ovom radu promatra se unutar šireg sustava korporativnog upravljanja. Korporativno upravljanje određuje odnose između vlasnika, nadzornih i upravljačkih tijela, dok upravljačka odgovornost

predstavlja skup očekivanih ponašanja čiju jezgru čine dvije međusobno povezane komponente: *accountability* i *responsibility* (OECD, 2023).

*Accountability* pritom označava obvezu agenta da polaže račune forumu koji ima pravo propitivati njegova postupanja, ocijeniti ih i odrediti posljedice u obliku sankcija ili nagrada (Bovens, 2007; Bovens, Schillemans i Goodin, 2014; Mulgan, 2000). *Responsibility* obuhvaća širu profesionalnu i etičku dimenziju odgovornosti, uključujući osjećaj moralne obveze koji proizlazi iz savjesti pojedinca (Mason i Simmons, 2014; Mulgan, 2000).

*Accountability* je utemeljen na vanjskoj kontroli, dok je *responsibility* utemeljen na osobnom integritetu pojedinca. U ovom radu naglasak je stavljen na mjerljivu dimenziju upravljačke odgovornosti (*accountability*), odnosno na prakse koje se mogu operacionalizirati kroz provjerljive indikatore kao što su postavljanje ciljeva, izvještavanje, vlasničko i nadzorno djelovanje, transparentnost i postojanje kontrolnih mehanizama (OECD, 2023).

## 3. METODOLOGIJA I UZORAK ISTRAŽIVANJA

Istraživanje je provedeno primjenom prilagođenog RELOF indeksa. RELOF indeks razvijen je u okviru projekta Reforma lokalnih finansija 3 (RELOF3) za mjerenje upravljačke odgovornosti na lokalnoj razini u Srbiji. Izvorni instrument obuhvaća tri stupa, 14 ključnih područja, 43 teme i 314 indikatora, a osim lokalnih javnih poduzeća uključuje i mjerenje upravljačke odgovornosti JLS-a i ostalih proračunskih korisnika JLS-a (RELOF3, 2024). Struktura RELOF indeksa prikazana je na Slici 1.

**Slika 1. Struktura RELOF indeksa**

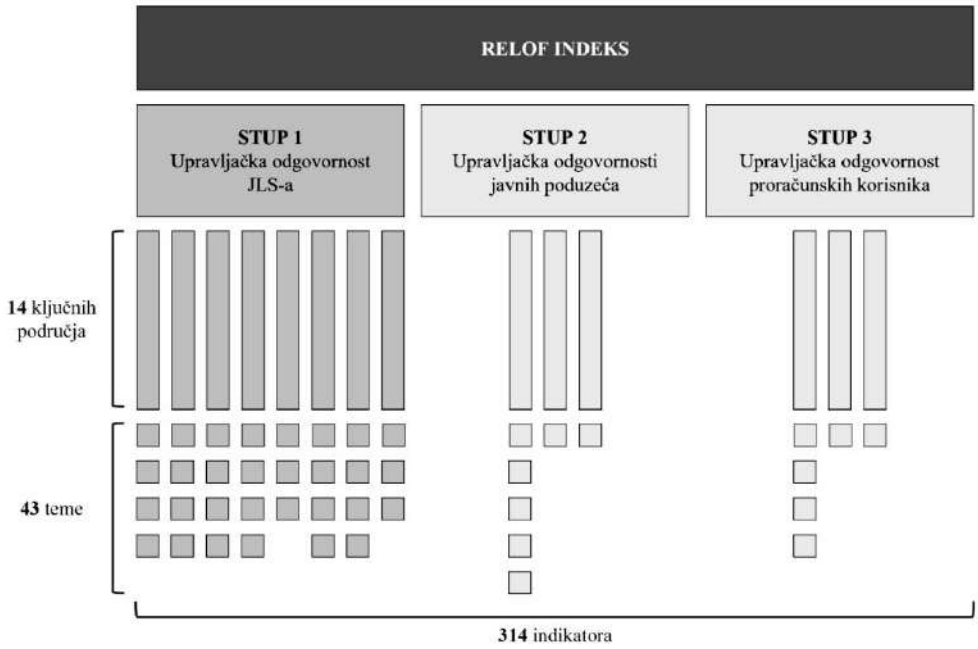


Izvor: izrada autora prema RELOF3 (2024).

Svi indikatori prilagođenog RELOF indeksa odnose se na mjerljivu dimenziju upravljačke odgovornosti, odnosno *accountability*. Iako se pojedini indikatori sadržajno odnose na područja poput etike, integriteta, sukoba interesa ili organizacijske kulture odgovornosti, njima se ne mjeri unutarnji osjećaj moralne i profesionalne obveze pojedinca (*responsibility*), nego postojanje i primjena konkretnih, objektivno provjerljivih organizacijskih praksi povezanih s tim područjima. *Responsibility* se stoga u ovom istraživanju ne mjeri zasebnom skupinom indikatora.

S obzirom na predmet ovog istraživanja, u odnosu na izvorni RELOF indeks napravljene su ukupno tri promjene, a ostatak indeksa ostao je nepromijenjen. Prvo, stup 3 (Upravljačka odgovornost proračunskih korisnika) izostavljen je u prilagođenom indeksu. Drugo, iz stupa 1 (Upravljačka odgovornost JLS-a) zadržano je jedno ključno područje i tema koja se odnosi na nadzor JLS-a nad radom poduzeća. Treće, prilagođeni su ponderi za stup 1 (Upravljačka odgovornost JLS-a) i stup 2 (Upravljačka odgovornost javnih poduzeća).

Izvorni ponderi triju stupova iznose 60 % za stup 1 (Upravljačka odgovornost JLS-a), 25 % za stup 2 (Upravljačka odgovornost javnih poduzeća) i 15 % za stup 3 (Upravljačka odgovornost proračunskih korisnika) (RELOF3, 2024). Nakon izostavljanja stupa 3, preraspodjelom preostalih pondera dobiveni su udjeli od 67,5 % za stup 1 i 32,5 % za stup 2. Budući da je izvorni RELOF indeks usmjeren na upravljačku odgovornost cijelog sustava JLS-a, dok je predmet ovog istraživanja upravljačka odgovornost javnih poduzeća, težinski su faktori invertirani kako bi se veći značaj dodijelio stupu koji neposredno odgovara predmetu istraživanja. Radi metodološke preglednosti konačni su ponderi zaokruženi na 30 % za stup 1 i 70 % za stup 2, dok su ponderi na nižim razinama indeksa zadržani nepromijenjenima.

Dodatno, sadržaj 55 indikatora preveden je i usklađen s hrvatskim pravnim i institucionalnim okvirom. U konačnici, prilagođeni instrument obuhvaća 55 indikatora raspoređenih u dva stupa, četiri ključna područja i osam tema. Struktura prilagođenog RELOF indeksa prikazana je na Slici 2.

**Slika 2. Struktura prilagođenog RELOF indeksa**

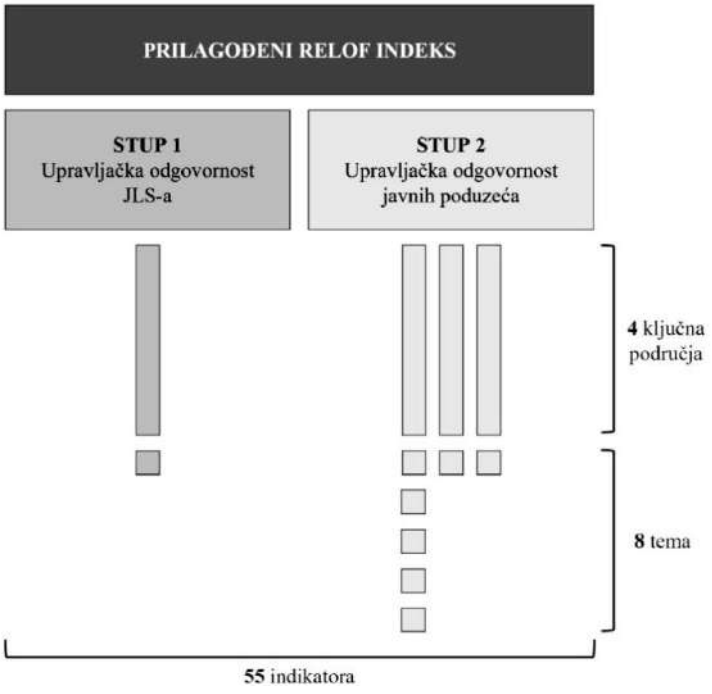


Izvor: prilagodba autora prema RELOF3 (2024).

Ponderi prilagođenog RELOF indeksa po stupovima, ključnim područjima i temama prikazani su u Tablici 1.

**Tablica 1. Struktura i težinski faktori prilagođenog RELOF indeksa**

| **1.** | **STUP** | **UPRAVLJAČKA ODGOVORNOST JLS-a** | **30 %** | | |
|---|---|---|---|---|---|
| 1.5. | KP | NADZOR NAD DIONICIMA IZVAN JLS-a | | 100 % | |
| 1.5.1. | Tema | Nadzor nad radom javnog poduzeća | | | 100 % |
| **2.** | **STUP** | **UPRAVLJAČKA ODGOVORNOST JAVNOG PODUZEĆA** | **70 %** | | |
| 2.1. | KP | KORPORATIVNO UPRAVLJANJE | | 80 % | |
| 2.1.1. | Tema | Posvećenost načelima korporativnog upravljanja | | | 10 % |
| 2.1.2. | Tema | Odnos javnog poduzeća s JLS-om | | | 25 % |
| 2.1.3. | Tema | Nadzorni odbor javnog poduzeća | | | 25 % |
| 2.1.4. | Tema | Uprava javnog poduzeća | | | 15 % |
| 2.1.5. | Tema | Nadzor, kontrola i vanjska revizija | | | 25 % |
| 2.2. | KP | TRANSPARENTNOST JAVNIH PODUZEĆA | | 10 % | |
| 2.2.1. | Tema | Transparentnost javnih poduzeća | | | 100 % |
| 2.3. | KP | ORGANIZACIJSKA KULTURA ODGOVORNOSTI | | 10 % | |
| 2.3.1. | Tema | Organizacijska kultura odgovornosti | | | 100 % |

Izvor: prilagodba autora prema RELOF3 (2024).

Vrijednost indeksa dobiva se procesom hijerarhijske agregacije, krećući se od najniže razine (indikatora) prema jedinstvenom zbirnom pokazatelju na vrhu (indeks). Maksimalna vrijednost indeksa koju je moguće ostvariti je 100 %, a minimalna 0 %, pri čemu viša vrijednost indeksa ukazuje na višu razinu kvalitete upravljačke odgovornosti i obrnuto (RELOF3, 2024). Na temelju vrijednosti indeksa izvodi se opisna ocjena kvalitete praksi upravljačke odgovornosti. Ocjene upravljačke odgovornosti prema vrijednosti indeksa prikazane su u Tablici 2.

**Tablica 2. Ocjene upravljačke odgovornosti prema vrijednosti indeksa**

| Vrijednost indeksa | Ocjena |
|---|---|
| 0,00 % – 34,99 % | Nedovoljno |
| 35,00 % – 49,99 % | Minimalno |
| 50,00 % – 64,99 % | Prosječno |
| 65,00 % – 79,99 % | Iznadprosječno |
| 80,00 % – 100,00 % | Izuzetno |

Izvor: prilagodba autora prema Jolović i Savanović Stevanović (2025).

Primarni podaci prikupljeni su pomoću dva upitnika: prvoga za JLS s 15 indikatora i drugoga za trgovačka društva s 40 indikatora. Upitnici su izrađeni prema metodologiji kartice postignuća. Poziv na sudjelovanje u istraživanju upućen je na 180 JLS-a, a pozivu se odazvalo njih 16 (8,89 %). Konačan uzorak obuhvaća 33 trgovačka društva iz 16 JLS-a koje se nalaze u 13 županija. Podaci su prikupljani od prosinca 2025. do svibnja 2026. U 2024. godini na lokalnoj razini, uključujući regionalnu (područnu) samoupravu, evidentirano je 796 javnih poduzeća, što odgovara približno 4 % navedenog ukupnog broja (Tipurić i sur., 2026).

Struktura uzorka pokazuje heterogenost obuhvaćenih JLS-a i javnih poduzeća. Od 16 JLS-a čija su poduzeća uključena u istraživanje, 75 % čine gradovi, a 25 % općine. Prema broju stanovnika, 25 % JLS-a ima manje od 5.000 stanovnika, 25 % između 5.000 i 20.000, 31 % između 20.000 i 50.000, a 19 % više od 50.000 stanovnika. U uzorku su zastupljene gotovo sve skupine JLS-a prema indeksu razvijenosti, osim III. skupine.

Strukturu 33 trgovačka društva prema djelatnosti čine komunalno gospodarstvo (42 %), održavanje okoliša (21 %), upravljanje imovinom (18 %), razvoj poduzetništva (12 %), transport (3 %) i opskrba energijom (3 %). Prema broju zaposlenih, 18 % poduzeća ima manje od 10 zaposlenih, 42 % između 10 i 50, 33 % između 50 i 250, a 6 % više od 250 zaposlenih. Prema ukupnim prihodima za 2025. godinu, 33 % poduzeća ostvaruje manje od milijun eura, 36 % između jednog i pet milijuna, 18 % između pet i deset milijuna, a 12 % više od deset milijuna eura (Financijska agencija [FINA], 2026). Budući da u istraživanju nisu korišteni usporedivi podaci o strukturi ukupne populacije prema djelatnosti, prihodima i broju zaposlenih, navedena

struktura služi opisu raznolikosti uzorka, a ne utvrđivanju njegove reprezentativnosti.

## 4. REZULTATI I RASPRAVA

Grafikon 1. prikazuje ukupni indeks za sva 33 ispitanika rangirana od najvišeg prema najnižem rezultatu. Puna horizontalna linija označava prag potreban za ostvarivanje minimalne razine upravljačke odgovornosti (35,00 %), dok isprekidana horizontalna linija označava prosječnu vrijednost ukupnog indeksa (45,80 %) za cijeli uzorak. Od 33 poduzeća njih 10 (30,30 %) nalazi se ispod praga minimalne upravljačke odgovornosti, 10 (30,30 %) je ostvarilo minimalnu, 7 (21,21 %) prosječnu i 6 (18,18 %) iznadprosječnu ocjenu upravljačke odgovornosti. Nijedno poduzeće nije ostvarilo izuzetnu razinu upravljačke odgovornosti.

**Grafikon 1. Usporedni prikaz ukupnog indeksa za cijeli uzorak**

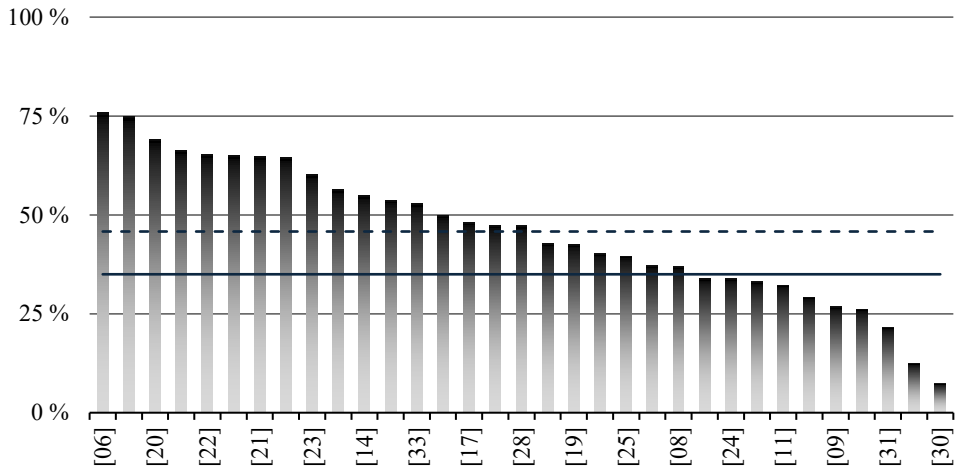


Izvor: istraživanje autora.

Razlaganje indeksa na razini stupova pokazuje izražen jaz između upravljačke odgovornosti vlasnika i poduzeća: prosječni indeks JLS-a iznosi 28,90 %, a prosječni indeks trgovačkih društava 52,48 %.

Analizom indikatora na razini stupa Upravljačka odgovornost JLS-a utvrđeno je da nijedna promatrana JLS ne izrađuje konsolidirano izvješće o

poduzećima u svojem vlasništvu, a većina nema jasno uređen postupak izrade i praćenja planova poslovanja. Jedinice lokalne samouprave uglavnom ne provode godišnju analizu poslovanja poduzeća niti tu analizu daju na usvajanje općinskom odnosno gradskom vijeću. Integrirana vlasnička politika izostaje kod svih ispitanih jedinica lokalne samouprave. Pozitivno je što su privremena imenovanja direktora rijetka, a izbor direktora provodi se javnim natječajem. Istodobno se komunikacija o ciljevima često odvija izravno između čelnika JLS-a i direktora poduzeća, čime se smanjuje institucionalna uloga nadzornog odbora.

Izostanak integrirane vlasničke politike, agregiranog izvještavanja i sustavnog praćenja poslovanja odstupa od preporuka o jasnim vlasničkim ciljevima i aktivnom nadzoru portfelja (Ministarstvo pravosuđa, uprave i digitalne transformacije RH, 2024; OECD, 2020, 2024). Slične slabosti prepoznate su i u hrvatskim revizijskim nalazima (Državni ured za reviziju, 2023). Istodobno, literatura upozorava da politička povezanost, personalizirani odnosi i nedovoljna profesionalizacija uprava i nadzornih odbora mogu oslabiti mehanizme odgovornosti (Bergh, Erlingsson, Gustafsson i Wittberg, 2019; Crnković, Požega i Karačić, 2011; Vagliasindi, 2008).

Od tri ključna područja unutar stupa Upravljačka odgovornost javnih poduzeća, najbolju ocjenu i najveći pozitivni doprinos ukupnom indeksu ostvaruje područje 2.2. Transparentnost javnih poduzeća (77,55 %), dok je najslabije ocijenjeno područje 2.1. Korporativno upravljanje (49,03 %). Najbolje pojedinačne prakse odnose se na objavu zakonom propisanih informacija, dok se među najslabijim praksama izdvajaju marginalizacija nadzornih odbora i izostanak kontinuirane edukacije njihovih članova. Kontrolna, strateška i povezujuća funkcija nadzornog odbora ključna je za djelotvorno korporativno upravljanje i upravljačku odgovornost (Tipurić i Cindrić, 2024).

Zadovoljavanje zakonskog minimuma i formalna usklađenost ne podrazumijevaju nužno visoke standarde upravljačke odgovornosti niti stvarnu odgovornost prema korisnicima i građanima (Royo, Yetano i García-Lacalle, 2019). Transparentnost smanjuje prostor za neetično djelovanje, ali njezin učinak ovisi o tome koristi li se objavljena informacija za stvarno pozivanje na odgovornost (Transparency International, 2017).

Budući da je korišteni indeks nastao prilagodbom RELOF indeksa, rezultati se mogu izravno usporediti s istraživanjem provedenim u Srbiji. Usporedno istraživanje provedeno je 2024. godine na uzorku od 45 javnih poduzeća u

vlasništvu jedinica lokalne samouprave u Srbiji (Jolović i Savanović Stevanović, 2025). Zbog razlike u obuhvatu izvornog i prilagođenog indeksa, usporedba se provodi isključivo na razini stupa Upravljačka odgovornost javnih poduzeća. Usporedni rezultati prikazani su na Grafikonu 2.

**Grafikon 2. Indeks upravljačke odgovornosti javnih poduzeća u Hrvatskoj i Srbiji**

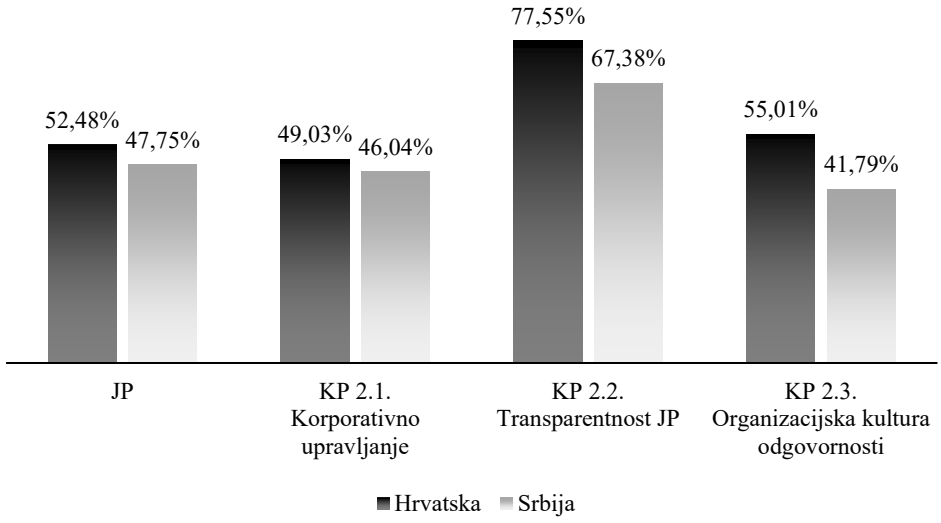


Izvor: podaci za Hrvatsku – istraživanje autora; podaci za Srbiju – Jolović i Savanović Stevanović (2025).

Hrvatska ostvaruje blagu do umjerenu prednost u svim promatranim kategorijama u odnosu na Srbiju. Na razini stupa Upravljačka odgovornost javnih poduzeća Hrvatska bilježi rezultat bolji za 4,73 postotna boda. Najmanja razlika zabilježena je u ključnom području 2.1. Korporativno upravljanje (2,99 postotna boda), dok Hrvatska ostvaruje izraženiju prednost u području 2.2. Transparentnost javnih poduzeća (10,17 postotnih bodova) i području 2.3. Organizacijska kultura odgovornosti (13,22 postotna boda).

Pri interpretaciji usporedbe Hrvatske i Srbije treba uzeti u obzir nekoliko razlika između istraživanja. Između njihova provođenja postoji vremenski razmak od približno dvije godine, pa rezultati ne prikazuju stanje u istom trenutku i moguće je da su se prakse u Srbiji u međuvremenu promijenile.

Osim toga, u Srbiji su podaci provjeravani kontrolnim posjetima i uvidom u dokumentaciju, dok se hrvatsko istraživanje temelji na samoprocjeni ispitanika (Jolović i Savanović Stevanović, 2025; RELOF3, 2024). Zbog toga dio razlika u rezultatima može biti posljedica različitog načina prikupljanja i provjere podataka.

Stoga blagu do umjerenu prednost Hrvatske treba tumačiti kao indikativnu, a ne kao dokaz razvijenijih praksi upravljačke odgovornosti. Unatoč snažnijem utjecaju europskoga regulatornog okvira i procesu pristupanja OECD-u, sličnost rezultata može upućivati na to da formalno prihvaćanje međunarodnih standarda samo po sebi nije dovoljno za njihovu stvarnu primjenu. Rezultati također mogu upućivati na trajnije tranzicijske obrasce, uključujući personalizaciju vlasničkog upravljanja i nedovoljno razvijenu institucionalnu ulogu nadzornih mehanizama, što je u skladu s literaturom koja upozorava na rizike političke povezanosti i nedovoljne profesionalizacije (Bergh i sur., 2019; Crnković i sur., 2011; Vagliasindi, 2008).

## 5. OGRANIČENJA ISTRAŽIVANJA

Rezultate treba tumačiti kao indikativne. Uzorak od 33 poduzeća obuhvaća približno 4 % populacije lokalnih javnih poduzeća. U provedbi istraživanja zabilježen je slab odaziv i nizak interes jedinica lokalne samouprave za predmet istraživanja. Pozivu se odazvalo svega 8,89 % gradova i općina kojima je poziv upućen.

Najveći dio njih ignorirao je upit za sudjelovanje u istraživanju (81,11 %), a jedinice lokalne samouprave koje su odbile sudjelovanje (10,00 %) najčešće su kao razloge navodile ograničene administrativne i kadrovske kapacitete, operativnu preopterećenost, potrebu za koordinacijom odgovora na razini JLS-a te opsežnost samog upitnika. Pojedini potencijalni ispitanici iskazali su i zabrinutost zbog mogućih nepovoljnih rezultata ili javne objave podataka, dok dio njih nije prepoznao izravnu korist ni vrijednost sudjelovanja u istraživanju.

Zbog navedenih razloga za odbijanje sudjelovanja postavlja se pitanje pristranosti odaziva. Postoji mogućnost da su u istraživanju većinom sudjelovale one jedinice lokalne samouprave i javna poduzeća koji već imaju uspostavljene kvalitetnije prakse upravljačke odgovornosti.

Dodatno ograničenje proizlazi iz metode samoprocjene. Izvorna RELOF metodologija predviđa kontrolne posjete i provjeru dokumentacije (RELOF3, 2024), što u ovom istraživanju zbog vremenskih i troškovnih ograničenja nije provedeno.

# 6. ZAKLJUČAK

Rezultati istraživanja upućuju na nedovoljno razvijene prakse upravljačke odgovornosti u upravljanju lokalnim javnim poduzećima. Prosječna vrijednost ukupnog indeksa iznosi 45,80 %, a 30,30 % ispitanih poduzeća ne doseže prag minimalne upravljačke odgovornosti. Najizraženiji deficit utvrđen je na razini JLS-a u ulozi vlasnika, uz izostanak integrirane vlasničke politike, konsolidiranog izvještavanja i sustavnog praćenja poslovanja. Na razini javnih poduzeća transparentnost je pritom najbolje, a korporativno upravljanje najslabije ocijenjeno područje.

Usporedba sa Srbijom pokazuje blagu do umjerenu prednost Hrvatske, ali i slične obrasce upravljanja, što upućuje na to da formalno prihvaćanje međunarodnih standarda samo po sebi ne osigurava njihovu stvarnu primjenu u praksi.

Središnji stručni doprinos rada proizlazi iz prilagodbe i primjene RELOF indeksa hrvatskom pravnom i institucionalnom okviru. Prilagođeni indeks predstavlja strukturirani dijagnostički i upravljački alat koji omogućuje objektivnu procjenu postojećih praksi, usporedbu poduzeća i kontinuirano praćenje razvoja upravljačke odgovornosti. Njegova periodična primjena na širem obuhvatu poduzeća može vlasnicima, nadzornim odborima i upravama pružiti mjerljivu osnovu za prepoznavanje nedostataka, praćenje napretka i usmjeravanje poboljšanja.

# LITERATURA

Bergh, A., Erlingsson, G., Gustafsson, A. i Wittberg, E. (2019). Municipally Owned Enterprises as Danger Zones for Corruption? How Politicians Having Feet in Two Camps May Undermine Conditions for Accountability. Public Integrity, 21(3), 320-352. https://doi.org/10.1080/10999922.2018.1522182

Bovens, M. (2007). Analysing and Assessing Accountability: A Conceptual Framework. European Law Journal, 13(4), 447-468. https://doi.org/10.1111/j.1468-0386.2007.00378.x

Bovens, M., Schillemans, T. i Goodin, R. E. (2014). Public Accountability. U M. Bovens, R. E. Goodin i T. Schillemans (Ur.), The Oxford Handbook of Public Accountability (str. 1-20). Oxford: Oxford University Press. https://doi.org/10.1093/oxfordhb/9780199641253.013.0012

Crnković, B., Požega, Ž. i Karačić, D. (2011). Izazovi korporativnog upravljanja u državnim poduzećima - Hrvatske perspektive. Ekonomski vjesnik, 24(2), 279-292. Dostupno na https://hrcak.srce.hr/76066

Državni ured za reviziju (2023). Objedinjeno izvješće o obavljenim financijskim revizijama trgovačkih društava u vlasništvu lokalnih jedinica [e-publikacija]. Dostupno na https://www.revizija.hr/UserDocsImages/izvjesca-novo/Revizije%20-%202022/IZVJESCA%20_O%20_OBAVLJENIM_REVIZIJAMA/FINANCIJSKE_REVIZIJE/TRGOVACKA_DRUSTVA_U_VLASNISTVU_JL/OBJEDINJENO%20IZVJESCE/OBJEDINJENO%20IZVJESCE%20-%20TD%20U%20VLASNISTVU%20LOKALNIH%20JEDINICA2.pdf

Financijska agencija (2026). Info.BIZ [podatkovni dokument]. Dostupno na https://infobiz.fina.hr/landing

Jolović, A. i Savanović Stevanović, S. (2025, 29. siječnja). RELOF indeks 2024.: Metodologija i rezultati [konferencija]. Predstavljanje rezultata RELOF indeksa za 2024. godinu, Aranđelovac, Srbija.

Mason, C. i Simmons, J. (2014). Embedding Corporate Social Responsibility in Corporate Governance: A Stakeholder Systems Approach. Journal of Business Ethics, 119(1), 77-86. https://doi.org/10.1007/s10551-012-1615-9

Ministarstvo pravosuđa i uprave RH (2020). Antikorupcijski program za trgovačka društva u većinskom vlasništvu jedinica lokalne i područne (regionalne) samouprave za razdoblje od 2021. do 2022. godine [e-

publikacija]. Dostupno na https://mpudt.gov.hr/UserDocsImages/dokumenti/Antikorupcija/Antikorupcijski%20program%20za%20trgovacka%20drustva%20u%20ve%C4%87inskom%20vlasni%C5%A1tvu%20jedinica%20lokalne%20i%20podrucne_regionalne%20samouprave_JLPRSza%20razdoblje%202021_2022.pdf

Ministarstvo pravosuđa, uprave i digitalne transformacije RH (2024). Priručnik za primjenu smjernica OECD-a o korporativnom upravljanju u trgovačkim društvima u većinskom državnom vlasništvu primjenjiv za trgovačka društva u većinskom vlasništvu jedinica lokalne i područne (regionalne) samouprave [e-publikacija]. Dostupno na https://mpudt.gov.hr/UserDocsImages/dokumenti/Antikorupcija/dokumenti/PRIRUCNIK_A4_WEB.pdf

Mulgan, R. (2000). Accountability: An Ever-Expanding Concept? Public Administration, 78(3), 555-573. https://doi.org/10.1111/1467-9299.00218

OECD (2020). Transparency and Disclosure Practices of State-Owned Enterprises and their Owners: Implementing the OECD Guidelines on Corporate Governance of State-Owned Enterprises [e-publikacija]. https://doi.org/10.1787/1ea99dbf-en

OECD (2021). OECD Review of the Corporate Governance of State-Owned Enterprises: Croatia [e-publikacija]. https://doi.org/10.1787/b4a46863-en

OECD (2023). G20/OECD Principles of Corporate Governance [e-publikacija]. https://doi.org/10.1787/ed750b30-en

OECD (2024). OECD Guidelines on Corporate Governance of State-Owned Enterprises [e-publikacija]. https://doi.org/10.1787/18a24f43-en

RELOF3 (2024). RELOF indeks - Praktični vodič za popunjavanje i korišćenje RELOF indeksa. RELOF3 Project.

Royo, S., Yetano, A. i García-Lacalle, J. (2019). Accountability Styles in State-Owned Enterprises: The good, the bad, the ugly... And the pretty. Revista de Contabilidad - Spanish Accounting Review, 22(2), 156-170. https://doi.org/10.6018/rcsar.382231

Tipurić, D. i Cindrić, L. (2024). Nadzorni odbor: korporativno upravljanje i grupna dinamika. Zagreb: CIRU.

Tipurić, D., Cindrić, L., Žuro, Z. i Idžojtić, A. (2026). Državno vlasništvo u globalnom gospodarstvu. U D. Tipurić (Ur.), Državna poduzeća: između ideologije, politike i učinkovitosti (str. 59-104). Zagreb: CIRU.

Transparency International (2017). 10 Anti-Corruption Principles for State-Owned Enterprises: A Multi-Stakeholder Initiative of Transparency International [e-publikacija]. Dostupno na https://images.transparencycdn.org/images/2017_SOE_Principles_Report_EN.pdf

Vagliasindi, M. (2008). Governance Arrangements for State Owned Enterprises (Policy Research Working Paper, br. 4542). Washington, DC: World Bank. https://doi.org/10.1596/1813-9450-4542

## NAPOMENA

Ovaj se rad temelji na istraživanju provedenom u sklopu autorova sveučilišnog specijalističkog rada „Analiza praksi upravljačke odgovornosti u trgovačkim društvima u vlasništvu jedinica lokalne samouprave u Hrvatskoj“, izrađenog pod mentorstvom prof. dr. sc. Darka Tipurića i obranjenog 2026. godine na Ekonomskom fakultetu Sveučilišta u Zagrebu.

# MANAGEMENT ACCOUNTABILITY IN MUNICIPALLY OWNED ENTERPRISES IN THE REPUBLIC OF CROATIA: AN ANALYSIS USING AN ADAPTED RELOF INDEX

***Abstract***

*This paper analyses the quality of management accountability practices in municipally owned enterprises in the Republic of Croatia. These enterprises manage public assets and provide services of direct importance to citizens, which makes the quality of their governance and accountability particularly important. The aim of the paper is to identify the key strengths and weaknesses of existing management accountability practices.*

*The empirical research was conducted on a sample of 33 municipally owned enterprises using an adapted RELOF Index. The original index was adjusted by modifying the weights of its components and aligning the indicators with the Croatian legal and institutional framework. Primary data were collected through questionnaires based on the scorecard methodology.*

*The results show that the average management accountability index amounts to 45.80%. None of the enterprises achieved the highest level of management accountability, while 30.30% remained below the minimum acceptable threshold. A marked difference was identified between municipalities as owners, with an average index of 28.90%, and the enterprises they own, with an average index of 52.48%. This gap indicates an insufficiently developed ownership role and the absence of an integrated ownership policy. A comparison with Serbia shows a slight to moderate advantage for Croatia, while also indicating that the formal adoption of international standards does not necessarily ensure their effective implementation in practice.*

*The main limitations arise from the relatively small sample, low response rate and potential response bias.*

*The contribution of the paper lies in the adaptation and application of the RELOF Index as both a research instrument and a diagnostic and management tool for assessing existing practices, comparing enterprises and monitoring the development of management accountability over time.*

***Keywords:*** *management accountability, corporate governance, municipally owned enterprises, management accountability index, measuring management accountability.*

JEL klasifikacija: K32, L15, Q55, Q58

Pregledni rad

# DIGITALNE PUTOVNICE ZA PROIZVODE

Ana Andabaka*

Jakov Grković**

## SAŽETAK

Digitalna putovnica za proizvode (engl. *Digital Product Passport* – DPP) predstavlja jedan od ključnih instrumenata Europske unije za provedbu ciljeva kružne ekonomije i održive tranzicije. U okviru novoga regulatornog okvira, posebice Uredbe o ekološkom dizajnu za održive proizvode (engl. *Ecodesign for Sustainable Products Regulation* – ESPR), digitalne putovnice trebaju omogućiti prikupljanje, pohranu i razmjenu informacija o podrijetlu, sastavu, održivosti, mogućnostima popravka, ponovne uporabe i recikliranja proizvoda tijekom njihova životnog ciklusa. Povećanjem transparentnosti i dostupnosti podataka DPP može doprinijeti učinkovitijem upravljanju resursima, jačanju povjerenja potrošača te stvaranju novih poslovnih modela temeljenih na načelima kružne ekonomije.

Cilj ovoga rada jest istražiti koncept digitalnih putovnica za proizvode koje predstavljaju neistraženo područje u domaćoj znanstvenoj i stručnoj literaturi te analizirati njihovu ulogu u tranziciji prema kružnoj ekonomiji. Poseban naglasak stavlja se na identificiranje ključnih očekivanih koristi, izazova i preduvjeta njihove buduće implementacije, s obzirom na to da će primjena digitalnih putovnica zahtijevati značajne organizacijske, tehnološke i

* Prof. dr. sc. Ana Andabaka, Sveučilište u Zagrebu, Ekonomski fakultet (e-mail: aandabaka@efzg.hr), korespondirajući autor.

** Jakov Grković (e-mail: jakovgrkovic15@gmail.com).

podatkovne prilagodbe poslovnih subjekata. U radu se primjenjuje metoda analize relevantne znanstvene i stručne literature te analiza europskog regulatornog okvira i strateških dokumenata povezanih s kružnom ekonomijom i digitalnom transformacijom.

Rezultati istraživanja upućuju na značajan potencijal digitalnih putovnica za proizvode u unapređenju sljedivosti materijala, donošenju održivijih odluka potrošača i poslovnih subjekata te povećanju učinkovitosti procesa ponovne uporabe, popravka i recikliranja. Istodobno, identificirani su izazovi povezani s interoperabilnošću sustava, standardizacijom podataka, zaštitom poslovno osjetljivih informacija te troškovima implementacije. Ograničenje istraživanja proizlazi iz činjenice da se regulatorni okvir za digitalne putovnice za proizvode još uvijek razvija te da njihova šira primjena u praksi tek predstoji. Zbog toga rad nije moguće temeljiti na empirijskim istraživanjima i iskustvima iz stvarne primjene, već se procjene potencijalnih učinaka temelje prije svega na regulatornim dokumentima i postojećim teorijskim spoznajama. Originalnost rada ogleda se u sustavnom pregledu koncepta digitalnih putovnica za proizvode te u povezivanju regulatornih zahtjeva, tehnoloških rješenja i ciljeva kružne ekonomije, čime se doprinosi razumijevanju regulatornih zahtjeva, potencijalnih koristi i izazova povezanih s budućom implementacijom digitalnih putovnica za proizvode u Republici Hrvatskoj i Europskoj uniji.

**Ključne riječi:** digitalna putovnica za proizvode, kružna ekonomija, održivi proizvodi, sljedivost, Europska unija.

# 1. UVOD

Model kružne ekonomije povezan je s potrebom za smanjenjem potrošnje prirodnih resursa i nastanka otpada te duljim očuvanjem funkcionalnosti i vrijednosti proizvoda. Imajući u vidu da kružna ekonomija obuhvaća puno više od recikliranja, sve se veća pozornost posvećuje trajnosti proizvoda kroz njihovo održavanje, popravljanje i ponovnu uporabu. Kroz Europski zeleni plan i Novi akcijski plan za kružno gospodarstvo, Europska unija (EU) naglasila je takav pristup kao ključan element svojih razvojnih politika, a ostvarenje postavljenih ciljeva podrazumijeva i potrebu za većom transparentnošću i dostupnošću informacija na temelju kojih će različite interesne skupine poput potrošača i proizvođača donositi svoje odluke o proizvodima.

Problem istraživanja proizlazi iz nedostupnosti pouzdanih podataka o podrijetlu, sastavu i svojstvima proizvoda, kao i o mogućnostima njihova popravljanja i recikliranja, ali i iz neadekvatne razmjene tih podataka. Navedeni nedostaci otežavaju očuvanje vrijednosti proizvoda tijekom njihova životnog vijeka i primjenu aktivnosti kružne ekonomije nakon njegova završetka. Europska unija zato nastoji pomoću digitalne putovnice za proizvode (engl. *Digital Product Passport* – DPP), koja je predmet ovog istraživanja, poduprijeti održiviju proizvodnju i potrošnju osiguravanjem dostupnosti sistematiziranih informacija o proizvodima.

Cilj rada jest objasniti koncept DPP-a i njegovu povezanost s kružnom ekonomijom, prikazati regulatorni okvir njegove primjene u Europskoj uniji te analizirati potencijalne koristi i izazove implementacije DPP-a. U skladu s tim, rad nastoji odgovoriti na tri pitanja: na koji način DPP može pridonijeti ostvarivanju ciljeva kružne ekonomije, kako regulatorni okvir EU-a uređuje njegovu primjenu te koje koristi, izazove i preduvjete implementacije treba razmotriti za različite skupine dionika.

U radu se primjenjuju metode analize i sinteze znanstvene i stručne literature te relevantnih regulatornih i strateških dokumenata. Ograničenje istraživanja proizlazi iz postupnog razvoja DPP-a, čija je primjena u praksi predviđena u 2027. godini, i ograničene dostupnosti empirijskih podataka o njegovim učincima te se zbog toga razmatraju prije svega potencijalne koristi DPP-a, uvjeti njihova ostvarenja i izazovi implementacije.

Originalnost rada ogleda se u povezivanju regulatornog okvira digitalnih putovnica za proizvode s njihovim potencijalnim koristima i izazovima za

različite skupine dionika. Znanstveni doprinos rada proizlazi iz objedinjavanja i kritičkog razmatranja postojećih saznanja te utvrđivanja preduvjeta pod kojima DPP može pridonijeti ostvarivanju ciljeva kružne ekonomije. Praktična vrijednost rada očituje se u konceptualnom prikazu DPP-a te sistematizaciji zahtjeva i prilagodbi koje gospodarski subjekti i tijela javne vlasti trebaju razmotriti pri pripremi za primjenu DPP-a u Republici Hrvatskoj (RH).

Rad je podijeljen u pet dijelova. Nakon uvodnog, drugi dio razmatra digitalnu putovnicu za proizvode u kontekstu kružne ekonomije. Treće poglavlje prikazuje regulatorni okvir i implementaciju DPP-a u Europskoj uniji, dok se u četvrtom analiziraju potencijalne koristi, izazovi i preduvjeti implementacije. Posljednji dio rada sadrži zaključna razmatranja.

## 2. DIGITALNA PUTOVNICA ZA PROIZVODE U KONTEKSTU KRUŽNE EKONOMIJE

Radi ubrzanja prijelaza na kružnu ekonomiju, Europska komisija (EK, 2020a) je u Novom akcijskom planu za kružno gospodarstvo iz 2020. godine predvidjela razvoj regulatornog okvira za održive proizvode. Planom je istaknuta potreba za proizvodima koji su dugotrajniji, ponovno uporabljivi, popravljivi i reciklabilni. Također, Plan je prepoznao digitalizaciju informacija o proizvodima i primjenu digitalnih tehnologija za njihovo praćenje kao temelj za razvoj digitalnih putovnica za proizvode i drugih rješenja koja podupiru kružnu ekonomiju i informirano odlučivanje potrošača (EK, 2020a). Međutim, na razini EU-a tada nije postojao sveobuhvatan skup zahtjeva kojim bi se osigurala održivost i kružnost proizvoda tijekom njihova životnog ciklusa. Nedostatak održivog dizajna, relevantnih informacija i cjenovno pristupačnih održivih proizvoda ograničavao je održive izbore potrošača, potražnju za sekundarnim materijalima i razvoj kružnih poslovnih modela. Uspostava zajedničkih zahtjeva za ekološki dizajn na razini EU-a stoga je prepoznata kao važan preduvjet za razvoj funkcionalnoga unutarnjeg tržišta održivih proizvoda i prijelaz na kružnu ekonomiju (Europski parlament i Vijeće Europske unije [EP i Vijeće EU-a], 2024a).

Sljedivost i transparentnost predstavljaju važnu osnovu za učinkovito upravljanje proizvodima tijekom njihova životnog ciklusa, osobito u kontekstu kružne ekonomije. Primjena digitalnih putovnica za proizvode omogućuje povezivanje relevantnih podataka s pojedinim proizvodom,

modelom ili serijom te njihovu dostupnost različitim sudionicima lanca vrijednosti. Na taj se način olakšava praćenje podrijetla, sastava, materijala, komponenti, uporabe, održavanja, popravaka i postupanja s proizvodom na kraju njegova životnog vijeka. DPP pritom pridonosi transparentnosti jer relevantne informacije čini dostupnima u strukturiranom i standardiziranom digitalnom obliku, uz definirana prava pristupa pojedinih dionika (EP i Vijeće EU-a, 2024a). Dostupnost takvih informacija može smanjiti informacijske asimetrije između proizvođača, potrošača, servisera, subjekata koji se bave obnovom i reciklažera te olakšati donošenje odluka povezanih s uporabom, popravkom, ponovnom uporabom i recikliranjem proizvoda.

DPP predstavlja elektroničku identifikacijsku iskaznicu za proizvode, komponente i materijale koja potrošačima, proizvođačima i tijelima javne vlasti (uključujući carinska tijela) olakšava procjenu održivosti, kružnosti i regulatorne usklađenosti (European Union, b. d.). Može se definirati i kao strukturirani skup podataka o proizvodu dostupan putem jedinstvene identifikacijske oznake i nosača podataka, s naglaskom na održivosti te očuvanju njegove vrijednosti za ponovnu uporabu, ponovnu proizvodnju i recikliranje (European Commission [EC], 2026a). Informacije sadržane u DPP-u ovise o konkretnom predmetnom proizvodu, a mogu uključivati tehničku učinkovitost, materijale i njihova podrijetla, aktivnosti popravaka, sposobnosti recikliranja te utjecaje na okoliš tijekom životnog ciklusa (European Union, b. d.).

Digitalna putovnica za proizvode može pridonijeti produljenju životnog vijeka proizvoda pružanjem informacija o njegovoj trajnosti, uporabi, održavanju, popravku i dostupnosti rezervnih dijelova. Podaci o sastavu, materijalima, mogućnostima rastavljanja i stanju proizvoda olakšavaju njegovu ponovnu uporabu, obnovu i prenamjenu te učinkovitije sortiranje i recikliranje materijala. Iako DPP sam po sebi ne produljuje životni vijek proizvoda, osiguravanjem relevantnih i strukturiranih informacija različitim dionicima smanjuje informacijske prepreke i podupire primjenu kružnih strategija zadržavanja vrijednosti proizvoda i materijala.

Ključni dionici na različit način ostvaruju interakciju s digitalnim putovnicama za proizvode te se mogu podijeliti u četiri kategorije: gospodarski subjekti, potrošači (kupci), subjekti koji se bave produljenjem životnog vijeka i oporabom proizvoda te tijela javne vlasti (Tablica 1.).

**Tablica 1. Vrste i obuhvat dionika u sustavu digitalnih putovnica za proizvode**

| Vrsta dionika | Obuhvat |
|---|---|
| Gospodarski subjekti | Proizvođač, ovlašteni zastupnik, uvoznik, distributer, trgovac i pružatelj usluge provođenja narudžbi. |
| Potrošači (kupci) | Fizičke ili pravne osobe koje kupe, unajme ili prime proizvod za vlastitu uporabu, bez obzira na to djeluju li u svrhe izvan svoje trgovačke, poslovne, obrtničke ili profesionalne djelatnosti. |
| Subjekti koji se bave produljenjem životnog vijeka i oporabom proizvoda | Subjekti koji profesionalno pružaju usluge popravka i održavanja (serviseri), subjekti koji se bave obnavljanjem proizvoda, subjekti koji se bave ponovnom proizvodnjom i reciklažeri. |
| Tijela javne vlasti | Nadležna nacionalna tijela, tijela za nadzor tržišta, carinska tijela, regulatorna tijela i tijela za izvršavanje, tijela javne uprave uključena u provedbu i koordinaciju te druga javna tijela nadležna za pitanja usklađenosti proizvoda. |

Izvor: prikaz autora na temelju EC-a (b. d.-a) te EP-a i Vijeća EU-a (2024a).

Različite kategorije dionika možemo promatrati i na način da razlikujemo dionike koji imaju obvezu izrade DPP-a i one koji koriste podatke sadržane u DPP-u odnosno osiguravaju primjenu DPP-a. Pristup podacima mora biti uređen prema ulogama i pravima pojedinih dionika, pri čemu relevantni korisnici trebaju imati jednostavan i besplatan pristup podacima u skladu sa svojim pravima pristupa (EP i Vijeće EU-a, 2024a). Gieß i Möller (2025) naglašavaju važnost jasnih pravila razmjene podataka među dionicima, čije se informacijske potrebe i uloge razlikuju tijekom životnog ciklusa proizvoda. Primarna odgovornost za izradu i točnost DPP-a pripada gospodarskim subjektima koji proizvod stavljaju na tržište EU-a, neovisno o tome jesu li proizvodi proizvedeni u EU-u ili uvezeni iz trećih zemalja. U slučaju prodaje proizvoda na daljinu, pružatelji internetskih platforma za trgovanje trebaju osigurati dostupnost DPP-a (EC, b. d.-b). Stavljanje proizvoda na tržište podrazumijeva prvo stavljanje proizvoda na raspolaganje na tržištu EU-a, tj. prvu isporuku proizvoda za distribuciju, potrošnju ili upotrebu u okviru trgovačke djelatnosti, uz naplatu ili besplatno (EP i Vijeće EU-a, 2024a). Odgovornosti gospodarskih subjekata obuhvaćaju prikupljanje i digitalnu dostavu podataka o proizvodu u skladu s propisanom strukturom podataka, registraciju digitalne putovnice za proizvode u Registru DPP-ova prije stavljanja proizvoda na jedinstveno tržište te osiguravanje točnosti i ažurnosti podataka tijekom cijelog životnog ciklusa proizvoda. Lyse i Huang (2026) u

sustavnom pregledu literature izdvajaju nedovoljno jasno definirane odgovornosti za upravljanje podacima kao jedan od nedostataka postojećih okvira DPP-a, što upućuje na potrebu njihova preciznog određivanja pri pripremi implementacije. Gospodarski subjekti također moraju osigurati postavljanje odgovarajućeg nosača podataka na proizvod, njegovu ambalažu ili prateću dokumentaciju, u skladu s propisima koji se primjenjuju na pojedinu skupinu proizvoda (EC, b. d.-b). Christensen, Stingl, Omair i Wæhrens (2025) ističu da oblikovanje sustava DPP-a treba uskladiti s ciljevima organizacije, informacijama potrebnima za donošenje odluka i odabranim kružnim praksama, što pruža osnovu za njegovo povezivanje s postojećim poslovnim procesima.

Potrošači će moći pristupiti pouzdanim, usporedivim i transparentnim informacijama o proizvodima na više jezika putem internetske poveznice ili skeniranjem nosača podataka, kao što je QR kod, putem pametnog telefona i na taj način donijeti informirane odluke o kupnji te bolje razumjeti proizvode koje koriste (EC, b. d.-b). Dionici poput servisera, reciklažera i subjekata koji se bave obnovom proizvoda koriste informacije o proizvodima u svakodnevnom poslovanju, pri čemu im DPP može omogućiti učinkovitije, informiranije i održivije poslovanje (EC, b. d.-b). Wan i Jiang (2025) predlažu okvir koji provjerenim korisnicima, poput servisera, omogućuje dopunjavanje DPP-a podacima o održavanju tijekom uporabe proizvoda, čime se podupire kontinuirano ažuriranje informacija o njegovu životnom ciklusu. DPP će poduprijeti tijela javne vlasti omogućavanjem učinkovitijeg i usklađenijeg nadzora provedbe propisa, automatizacije i koordinacije te poboljšanjem nadzora tržišta putem standardiziranog pristupa relevantnim strojno čitljivim podacima (EC, b. d.-b). Nadležna nacionalna tijela odgovorna su za provedbu Uredbe o ekološkom dizajnu za održive proizvode i primjenu DPP-a na području država članica. Tijela za nadzor tržišta provjeravaju usklađenost proizvoda sa zahtjevima, mogu poduzimati mjere za smanjenje rizika te nadziru tijela za ocjenjivanje sukladnosti, dok države članice utvrđuju sankcije za povrede propisa. Carinska tijela provode kontrole na vanjskim granicama EU-a kako bi osigurala da proizvodi prije puštanja u slobodan promet imaju odgovarajući DPP. Dodatni oblik osiguravanja primjene DPP-a predstavlja privatno djelovanje kupaca kroz njihovo pravo da zahtijevaju naknadu štete nastale zbog neusklađenih proizvoda od proizvođača, odnosno, ovisno o okolnostima, od uvoznika, ovlaštenog zastupnika ili pružatelja usluga provođenja narudžbi (EP i Vijeće EU-a, 2024a).

# 3. REGULATORNI OKVIR I IMPLEMENTACIJA DIGITALNIH PUTOVNICA U EUROPSKOJ UNIJI

Ključni elementi regulatornog okvira povezanog s konceptom DPP-a uključuju meko pravo (engl. *soft law*) u obliku Europskog zelenog plana, Novog akcijskog plana za kružno gospodarstvo i Nove industrijske strategije za Europu, kao i sekundarno pravo EU-a u obliku Uredbe o ekološkom dizajnu za održive proizvode. Europski zeleni plan utvrđen u prosincu 2019. usmjerava Europsku uniju prema klimatski neutralnom, konkurentnom i kružnom gospodarstvu, pri čemu digitalizacija predstavlja važan alat zelene tranzicije. Budući da postojeći linearni modeli proizvodnje i potrošnje stvaraju znatan pritisak na resurse i okoliš, Plan naglašava potrebu za održivijim proizvodima i pouzdanim, usporedivim i provjerljivim informacijama koje potrošačima omogućuju donošenje informiranih odluka i smanjuju rizik od „zelenog marketinga". U tom kontekstu, digitalne putovnice za proizvode prepoznate su kao jedno od digitalnih rješenja koje omogućuje dostupnost podataka o podrijetlu, sastavu, mogućnostima popravka i rastavljanja te postupanju s proizvodom na kraju njegova životnog vijeka, čime se podupire razvoj kružne ekonomije (EK, 2019).

Nova industrijska strategija za Europu, koja je donesena 2020. i ažurirana 2021. godine, utvrđuje ambiciju EU-a za usporednu tranziciju prema klimatskoj neutralnosti i digitalnom vodstvu. Strategija naglašava potrebu smanjivanja ugljičnog i materijalnog otiska industrije te uključivanja načela kružnosti u cijelo gospodarstvo, što zahtijeva promjenu načina oblikovanja, proizvodnje, uporabe i zbrinjavanja proizvoda (EK, 2020b). U tom kontekstu DPP predstavlja jedno od digitalnih rješenja koje može poduprijeti ciljeve industrijske strategije omogućavanjem transparentnijeg pristupa podacima o proizvodima, materijalima i njihovim svojstvima tijekom životnog ciklusa te smanjenjem ovisnosti u uvozu sirovina.

Uredba o ekološkom dizajnu za održive proizvode, službeno poznata pod nazivom Uredba (EU) 2024/1781, stupila je na snagu 18. srpnja 2024. i predstavlja pravnu osnovu za DPP[1]. Cilj ove Uredbe jest uspostava regulatornog okvira koji će poduprijeti provedbu Europskoga zelenog plana, prijelaz prema kružnoj ekonomiji i novu europsku industrijsku strategiju tako što će pristup ekološkom dizajnu učiniti primjenjivim na najširi mogući

[1] Navedena Uredba zamjenjuje Direktivu o ekološkom dizajnu (Direktiva 2009/125/EZ) te proširuje područje njezine primjene.

raspon proizvoda. Kružnost se odnosi na stupanj u kojem se sastavni materijali proizvoda pri kraju životnog vijeka mogu opetovano produktivno upotrebljavati, stvarajući tako dodanu vrijednost (European Union, b. d.), dok ekološki dizajn podrazumijeva „uključivanje aspekata okolišne održivosti u značajke proizvoda i procese koji se odvijaju u cijelom lancu vrijednosti proizvoda" (EP i Vijeće EU-a, 2024a, čl. 2. t. 6.). Zahtjevi za ekološki dizajn potencijalno mogu obuhvatiti svu fizičku robu koja se stavlja u uporabu ili na tržište EU-a, uz neke iznimke kao što su hrana i hrana za životinje, lijekovi i aspekti vozila koji su već obuhvaćeni sektorskim zakonodavnim aktima EU-a te proizvodi za obranu i nacionalnu sigurnost koji nemaju dvojnu namjenu (European Union, b. d.).

Zahtjevi za ekološki dizajn osmišljeni su radi (European Union, b. d.):

a) poboljšanja trajnosti, mogućnosti ponovne uporabe, nadogradnje i popravka;

b) pojednostavnjenja proizvoda radi ponovne proizvodnje i recikliranja;

c) povećanja udjela recikliranog sadržaja;

d) rješavanja prisutnosti tvari koje onemogućuju kružnost;

e) rješavanja pitanja uništenja neprodanih proizvoda široke potrošnje;

f) povećanja energetske učinkovitosti proizvoda i učinkovitosti resursa proizvoda;

g) smanjenja ugljičnog i ekološkog otiska;

h) poboljšanja dostupnosti informacija o održivosti proizvoda.

Vlada Republike Hrvatske je 26. kolovoza 2026. u hitnu saborsku proceduru uputila Prijedlog zakona o provedbi Uredbe (EU) 2024/1781 kako bi uspostavila nacionalni okvir za primjenu Uredbe kojom se transformira pristup održivosti proizvoda na unutarnjem tržištu EU-a. Predloženim Zakonom određuju se nadležna tijela i uređuju nadzor, ocjenjivanje sukladnosti i sankcije za provedbu Uredbe u RH, uz propisivanje mjera za sprječavanje uništavanja neprodanih proizvoda široke potrošnje (Ministarstvo gospodarstva, 2026).

Osnovni zahtjevi povezani s DPP-om obuhvaćaju dostupnost DPP-a prije stavljanja proizvoda na tržište, osiguravanje točnih, potpunih i ažurnih podataka, jedinstvenu identifikaciju proizvoda, uporabu odgovarajućeg nosača podataka, interoperabilnost i strojnu čitljivost podataka, uređivanje

prava pristupa te njihovu dostupnost tijekom odgovarajućeg razdoblja. Gospodarski subjekti pritom snose odgovornost za registraciju DPP-a u digitalnom registru koji ne predstavlja centralno spremište cjelokupnog sadržaja DPP-a, već prije svega služi za registraciju jedinstvenih identifikacijskih oznaka i drugih propisanih podataka te povezivanje proizvoda s njegovim decentraliziranim DPP-om.

Kako bi omogućila da DPP zaživi u praksi gospodarskih subjekata koji proizvode stavljaju na tržište Europske unije, Europska komisija je 20. srpnja 2026. pokrenula Registar digitalnih putovnica za proizvode (engl. *Digital Product Passport Registry – DPP Registry*) uključujući testno okruženje. Pristup testnom okruženju, zajedno s tehničkom dokumentacijom, smjernicama za provedbu, webinarima i najnovijim informacijama, dostupan je putem novih internetskih stranica za digitalne putovnice za proizvode[2]. Bitna uloga testne faze je olakšavanje prve primjene DPP-a koja je predviđena 18. veljače 2027. za određene vrste velikih baterija (EC, 2026b)[3]. Uvođenjem DPP-a za propisane vrste baterija[4], koncept DPP-a će zaživjeti u praksi, a potom će uslijediti postupno uvođenje i za ostale prioritetne kategorije proizvoda. U sljedećem razdoblju obveza primjene DPP-a obuhvatit će tekstil, željezo i čelik, građevne proizvode, proizvode informacijsko-komunikacijske tehnologije, gume, aluminij, deterdžente, namještaj, igračke itd. Ovisno o obilježjima pojedine skupine proizvoda, DPP može se uspostaviti na razini modela, serije ili pojedinačnog primjerka. Dok modelna razina omogućuje primjenu istih podataka na sve proizvode istog modela, razina pojedinačnog primjerka omogućuje praćenje podataka specifičnih za svaki proizvod tijekom njegova životnog ciklusa (EP i Vijeće EU-a, 2024a), što je osobito relevantno za baterije.

Pokretanju Registra prethodilo je donošenje Provedbene uredbe Komisije (EU) 2026/1778 kojom se utvrđuju praktična pravila za uspostavu i funkcioniranje Registra, čime je ključna sastavnica sustava digitalnih putovnica za proizvode stavljena u funkciju (EC, 2026b). Kako bi gospodarski subjekti mogli registrirati DPP-ove i kasnije njima upravljati,

[2] https://single-market-economy.ec.europa.eu/single-market/digital-product-passport/dpp-registry_en

[3] Potkraj kolovoza 2026. godine nije bilo moguće uspješno registrirati DPP-ove za baterije jer semantički katalog za tu skupinu proizvoda još nije bio definiran.

[4] DPP-om su obuhvaćene tri kategorije: baterije za električna vozila (hibridna i potpuno električna vozila), baterije za laka prijevozna sredstva (kao što su električni bicikli i električni romobili) i industrijske baterije s kapacitetom većim od 2 kWh.

potrebna je provjera organizacije u Registru koja služi za identifikaciju. Postupak koji prolazi organizacija koja po prvi put registrira DPP obuhvaća tri faze i njezini su koraci prikazani slikom 1.

**Slika 1. Postupak za nove gospodarske subjekte u Registru digitalnih putovnica za proizvode**

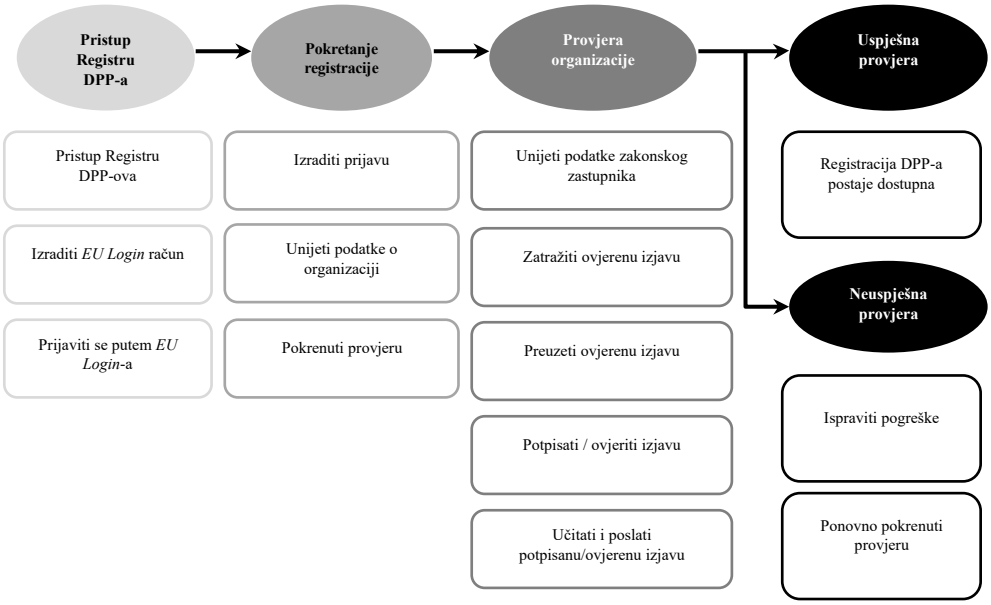


Izvor: EC (2026a).

Prva faza je pristup Registru, pri čemu je potrebno izraditi i koristiti korisnički račun *EU Login* za autentifikaciju. Druga faza je registracija i provjera organizacije, tijekom koje korisnik nakon prijave dostavlja tražene podatke o organizaciji, koje Europska komisija provjerava. Nakon uspješne provjere korisnik dobiva ulogu administratora organizacije i pristup funkcijama Registra u skladu sa svojim ovlastima. Treća faza je registracija DPP-a, pri čemu gospodarski subjekt za pripremljenu digitalnu putovnicu dostavlja propisane podatke jednim od dostupnih načina podnošenja, uključujući jedinstvenu identifikacijsku oznaku proizvoda koja mora omogućiti pristup lokaciji na kojoj su pohranjeni podaci DPP-a (EC, 2026a). Upravo testno okruženje omogućava gospodarskim subjektima sigurno testiranje postupaka i funkcionalnosti Registra bez utjecaja na službene podatke. Za pristup

testnom okruženju potrebno je koristiti zaseban račun *EU Login*, dok je postupak provjere organizacije jednak onome u produkcijskom okruženju, a podaci i objekti kreirani tijekom testiranja mogu biti naknadno izbrisani. U okviru testnog okruženja dostupna je i poveznica na korisničku službu koja pruža tehničku podršku u obliku smjernica, dokumentacije i resursa za podršku organizacijama u korištenju Registra (EC, 2026a).

Gospodarski subjekt koji je uspješno proveo postupak provjere identiteta u Registru naziva se provjereni gospodarski subjekt, ali i drugi akteri u lancu vrijednosti moraju proći kroz postupak provjere kako bi mogli dobiti pristup Registru (EK, 2026). Pri stavljanju proizvoda na tržište gospodarski subjekt stavlja na raspolaganje pričuvnu kopiju DPP-a putem neovisne treće strane, tj. provjerenog pružatelja usluge digitalne putovnice za proizvode (EP i Vijeće EU-a, 2024a), čime se nastoji osigurati dugoročna dostupnost podataka. Provjereni gospodarski subjekt i provjereni akter u lancu vrijednosti odgovorni su za točnost, potpunost i ažurnost podataka u Registru, uključujući podatke o promjenama pravnih zastupnika. Provjereni gospodarski subjekt dužan je primjenjivati odgovarajuće tehničke i organizacijske sigurnosne mjere radi sprječavanja neovlaštenog pristupa ili izmjene registracijskih podataka preko svojeg informacijskog sustava (EK, 2026).

Postupak funkcioniranja DPP-a moguće je prikazati kroz pet koraka (Slika 2.) koji započinju prikupljanjem podataka te završavaju osiguravanjem transparentnosti i usklađenosti.

**Slika 2. Funkcioniranje DPP-a u pet koraka**

Izvor: prikaz autora prema opisu postupka Europske komisije (EC, b. d.-a).

Gospodarski subjekti prikupljaju podatke o proizvodu koje propisuje zakonodavstvo EU-a, nakon čega se DPP izrađuje i registrira u Registru, dok se potpuni podaci pohranjuju kod gospodarskog subjekta ili pružatelja usluge DPP-a te se fizički proizvod povezuje s DPP-om putem nosača podataka.

Nakon registracije DPP-a, Registar generira jedinstveni registracijski identifikator (engl. *unique registration identifier* – URI), koji omogućuje identifikaciju DPP-a i provjeru registracije proizvoda, uključujući pri uvozu. Različiti korisnici pristupaju informacijama DPP-a skeniranjem podatkovnog nosača, pri čemu se pristup podacima određuje prema njihovim ulogama i pravima pristupa. Konačno, DPP povećava transparentnost i podržava usklađenost jer potrošačima omogućuje informiraniji odabir, serviserima i reciklažerima pristup relevantnim podacima, a javnim tijelima provjeru usklađenosti i učinkovitiji nadzor tržišta (EC, b. d.-a).

# 4. POTENCIJALNE KORISTI I IZAZOVI IMPLEMENTACIJE DIGITALNIH PUTOVNICA ZA PROIZVODE

DPP povezuje regulatorne zahtjeve s upravljanjem informacijama tijekom životnog ciklusa proizvoda. Za gospodarske subjekte obuhvaćene prethodno navedenim propisima, ona predstavlja regulatornu obvezu, ali i mogućnost unapređenja poslovanja u kontekstu kvalitetnije razmjene podataka te posljedično mogućeg povećanja dodane vrijednosti samog proizvoda. Ostvarenje potencijalnih koristi DPP-a ovisi o tome koliko su dostupni podaci razumljivi i primjenjivi u praksi, primjerice pri kupnji, popravku ili recikliranju proizvoda (EC, b. d.-b).

U nastavku se analiziraju potencijalne koristi DPP-a za pojedine kategorije dionika, a zatim se razmatraju ključni izazovi i preduvjeti implementacije DPP-a. Iako se digitalnim putovnicama za proizvode pripisuje značajan potencijal za unapređenje održivosti, empirijski dokazi o njihovim učincima još uvijek su ograničeni (Psarommatis i May, 2026) te će upravo prijelaz s teorijskih modela na primjenu u stvarnim lancima vrijednosti omogućiti precizniju evaluaciju njihove učinkovitosti i prepoznavanje provedbenih izazova.

## 4.1. Potencijalne koristi za pojedine skupine dionika

Za proizvođače i druge gospodarske subjekte potencijalne koristi DPP-a prije svega proizlaze iz veće dostupnosti podataka o materijalima i njihovu podrijetlu, kao i o svojstvima proizvoda. Transparentnije informacije o proizvodima mogu poduprijeti dokazivanje kvalitete, a potencijalno i razlikovanje ponude na tržištu (EC, b. d.-b), što može predstavljati jednu od

konkurentskih prednosti gospodarskih subjekata u kontekstu prodaje proizvoda. Nadalje, smatra se da će dostupnost informacija o sastavu proizvoda, proizvodnom procesu te životnom ciklusu proizvoda pomoći poslovnim subjektima pri izboru materijala i u procesu unapređenja dizajna. Ipak, odabir podataka pritom treba povezati s konkretnom poslovnom uporabom, uz razlikovanje regulatorno obveznih i dodatnih informacija (Trienens, Orlowski, Schröder, Hovemann i Dumitrescu, 2025). Iz toga proizlazi da veća količina podataka sama po sebi ne stvara konkurentsku prednost za poduzeće u kontekstu proizvodnje, već poduzeće mora razviti sposobnost njihove analize i primjene u poslovnim odlukama.

U distribuciji i trgovini, jedna od istaknutih prednosti DPP-a je da može olakšati povezivanje informacija o proizvodu s prodajom i postprodajnim aktivnostima. Studija o tekstilnom sektoru prepoznaje trgovce kao korisnike takvog sustava te naglašava pomak s općih tvrdnji o poduzeću prema transparentnosti informacija o konkretnom proizvodu (Legardeur i Ospital, 2024). Iz takve povezanosti može se izvesti potencijalna korist za upravljanje ponudom jer bi trgovci lakše uspoređivali dokumentaciju dobavljača, odgovarali na upite kupaca i usmjeravali vraćene proizvode prema daljnjoj prodaji ili obnovi. Uštede u administraciji ipak ovise o povezivanju DPP-a s postojećim prodajnim i informacijskim sustavima jer bi paralelno ručno vođenje evidencija moglo i povećati opterećenje.

Za potrošače se potencijalne koristi očituju u mogućnosti usporedbe proizvoda prema sastavu, trajnosti, popravljivosti te prema utjecaju na okoliš, ovisno o dostupnim podacima za pojedinu skupinu proizvoda. Cilj je dostupnošću informacija smanjiti informacijski jaz između prodavatelja i kupaca te kupcima pomoći u donošenju odgovornijih i boljih potrošačkih odluka koje bi u razmatranje mogle uzeti i buduće troškove uporabe, održavanja i popravljanja. Dostupnost uputa za uporabu i popravak može biti posebno korisna i nakon kupnje (EC, b. d.-c), a njihova digitalna dostupnost može pridonijeti smanjenju potrebe za papirnatom dokumentacijom (DIGITALEUROPE, 2023). Ipak, pristup informacijama ne podrazumijeva i njihovo razumijevanje te je potreban jasan prikaz prilagođen korisniku jer tehnički složeni i neprilagođeni podaci mogu otežati korištenje dostupnih informacija u željene svrhe. Osim dostupnosti i razumljivosti informacija, empirijsko istraživanje provedeno primjenom modeliranja strukturnih jednadžbi utvrđuje da na spremnost potrošača na korištenje DPP-a značajno utječu i povjerenje u DPP, želja za dodatnim informacijama o proizvodu te proekološki stavovi (Simões, Neves, Oliveira, Azadi i Goli, 2026). Nalazi

naglašavaju važnost vrijednosti, motivacije i povjerenja potrošača kao dionika u primjeni DPP-a i ostvarivanju njegova potencijala za održiviju potrošnju. Iako DPP pruža potporu informiranijem izboru, njegova implementacija i korištenje ne jamče odabir održivijeg proizvoda (Psarommatis i May, 2026), pa ostvarivanje očekivanih koristi ovisi i o spremnosti potrošača da u svoje odluke i obrasce ponašanja uključe vrijednosti i načela kružne ekonomije.

Tijekom uporabe proizvoda posebno dolaze do izražaja koristi za servisere i pružatelje usluga popravka. Pristup detaljnim uputama za rastavljanje, popisu odgovarajućih rezervnih dijelova i dijagnostičkim informacijama može olakšati identifikaciju kvara i popravak, što može pridonijeti dugovječnosti proizvoda. Opseg dostupnih informacija pritom ovisi o skupini proizvoda, primjenjivom zakonodavstvu i pravima pristupa (EC, b. d.-d). DPP može povećati ekonomsku opravdanost popravka olakšavanjem pristupa relevantnim informacijama, dok Direktiva EU-a o pravu na popravak dodatno podupire popravak zahtjevom da proizvođači rezervne dijelove i alate koje nude za propisane proizvode stavljaju na raspolaganje po razumnim cijenama koje ne odvraćaju od popravka (EP i Vijeće EU-a, 2024b, čl. 5. st. 4.). Ostvarenje koristi zato ovisi o povezivanju informacija DPP-a s provedbom regulatornih zahtjeva i dostupnošću servisnih usluga.

Koristi za subjekte koji se bave ponovnom uporabom, obnovom i recikliranjem nadovezuju se na mogućnosti produljenja životnog vijeka proizvoda. Podaci o proizvodu mogu poduprijeti procjenu mogućnosti obnove, dok informacije o sastavu, vrijednim materijalima i zabrinjavajućim tvarima mogu poboljšati razvrstavanje i izbor postupka obrade. Posebna korist za reciklažere proizlazi iz lakšeg prepoznavanja komponenata koje treba izdvojiti radi sigurnog postupanja i oporabe vrijednih sirovina (EC, b. d.-d). Na toj se osnovi može prepoznati potencijal DPP-a za dobivanje kvalitetnijih sekundarnih sirovina i njihovo ponovno uključivanje u proizvodnju te samim time poticanje kružne ekonomije. Reich, Ayan, Alaerts i Van Acker (2023) proveli su empirijsko istraživanje Delphi metodom među 28 stručnjaka kako bi procijenili potencijal putovnica za proizvode u primjeni kružnih strategija u sektoru elektronike. Prema procjenama ispitanika, informacije sadržane u putovnicama mogu unaprijediti recikliranje, prenamjenu, ponovnu proizvodnju, obnovu, popravak i ponovnu uporabu elektroničkih proizvoda. Ipak, podaci o sastavu ne uklanjaju fizička ograničenja odvajanja materijala ni potrebu za sustavima prikupljanja. Kvalitetnije recikliranje zahtijeva povezivanje informacija s odgovarajućom

tehnologijom obrade, dovoljnim količinama prikupljenog otpada i potražnjom za sekundarnim sirovinama.

Osim potrošačima i poslovnim subjektima, DPP može koristiti i javnim tijelima nadležnima za nadzor tržišta i provedbu propisa. Pristup relevantnoj dokumentaciji i podacima može olakšati provjeru usklađenosti proizvoda, koordinaciju nadležnih tijela i usmjeravanje kontrola. U carinskim postupcima digitalne provjere registracijskih podataka mogu poduprijeti učinkovitije upravljanje rizicima (EC, b. d.-e). Moguća korist jest i rasterećenje dijela administrativnih postupaka, čime bi se više kapaciteta moglo usmjeriti na rizičnije proizvode. Međutim, dostupnost dokumentacije ne može zamijeniti provjeru njezine vjerodostojnosti ni ispitivanje stvarnih svojstava proizvoda kada je ono potrebno.

Koristi za navedene dionike mogu se povezati i s razvojem kružnih poslovnih modela, poput najma, ponovne prodaje i organiziranog povrata proizvoda. Posljedično, može se zaključiti da DPP može poduprijeti i model proizvoda kao usluge ako pruža informacije potrebne za održavanje i procjenu preostale uporabne vrijednosti (Legardeur i Ospital, 2024). Doprinos DPP-a ovisi o razini detaljnosti podataka jer informacije o modelu proizvoda ne pružaju nužno uvid u stanje svakog pojedinačnog primjerka.

## 4.2. Izazovi i preduvjeti implementacije digitalnih putovnica za proizvode

Ostvarenju navedenih koristi prethodi uspješna implementacija DPP-a koja je povezana s nizom podatkovnih, financijskih, tehnoloških, ali i organizacijskih izazova. Primjena DPP-a uključuje troškove implementacije koji se mogu podijeliti u dvije kategorije. Početni troškovi obuhvaćaju prikupljanje nedostajućih podataka, prilagodbu informacijskih sustava i osposobljavanje zaposlenika, dok trajni uključuju održavanje, pohranu i ažuriranje informacija. Istodobno, potreba za osposobljavanjem prisutna je i kod tijela javne vlasti, zbog čega je Vlada RH najavila planirana financijska sredstva u iznosu od oko 863,6 tisuća eura za dodatnu obuku i zapošljavanje novih inspektora u različitim tijelima u razdoblju od 2027. do 2029. godine kako bi se osigurala provedba zakona o provedbi Uredbe (EU) 2024/1781 (Vlada RH, 2026). Ograničena financijska sredstva i nedostatak stručnog osoblja mogu uvođenje DPP-a u poslovanje posebno otežati malim i srednjim poduzećima (Psarommatis i May, 2026) koja će morati uvesti nove informacijske sustave

i procese upravljanja podacima. Može se pretpostaviti da će poduzeća nastojati dio troškova implementacije DPP-a prenijeti na krajnje kupce povećanjem cijena proizvoda, dok će intenzitet istog ovisiti o tržišnim uvjetima.

Pri procjeni opravdanosti ulaganja važno je razmotriti raspodjelu troškova i koristi među dionicima. Proizvođač može snositi znatan dio troškova pripreme podataka, dok se dio koristi ostvaruje kod servisera i reciklažera. Zbog toga pozitivan učinak DPP-a na cijeli lanac vrijednosti ne podrazumijeva nužno brz povrat ulaganja za pojedino poduzeće. Za manja poduzeća zajednička sektorska rješenja, edukacija i razmjena postojećih podataka mogu smanjiti troškove i olakšati prilagodbu.

Ključan izazov predstavlja i osiguravanje kvalitetnih podataka, a prije uspostave DPP-a potrebno je utvrditi relevantne informacije i prepoznati nedostatke u postojećim evidencijama (Trienens i sur., 2025). Složenost upravljanja podacima i nespremnost partnera na njihovu razmjenu mogu otežati implementaciju (Abedi, Saari i Hakola, 2024), a budući da netočni ili zastarjeli podaci mogu otežati popravak i obradu proizvoda, potrebno je utvrditi i njihove izvore, način provjere i postupak ispravljanja pogrešaka. S time je povezano pitanje odgovornosti za točnost i ažurnost podataka koju Europska komisija primarno povezuje s gospodarskim subjektima koji proizvod stavljaju na tržište (EC, b. d.-b).

Djelotvorna razmjena podataka zahtijeva njihovu standardizaciju i interoperabilnost informacijskih sustava. Standardizacija podrazumijeva usklađivanje strukture, značenja i načina iskazivanja podataka, dok interoperabilnost omogućuje njihovu razmjenu i uporabu u različitim sustavima. Usklađene norme predstavljaju ključan element tehničkog okvira potrebnog za implementaciju DPP-a na razini Europske unije[5], zbog čega njihov razvoj treba pratiti primjena i povezivanje s već postojećim informacijskim sustavima (CEN-CENELEC, 2026). Uredba o ekološkom

[5] Prva serija usklađenih europskih normi za DPP, objavljena u svibnju 2026. godine, obuhvatila je šest od ukupno osam normi: protokole za razmjenu podataka (EN 18216:2026), jedinstvene identifikacijske oznake (EN 18219:2026), nosače podataka (EN 18220:2026), pohranu, arhiviranje i postojanost podataka (EN 18221:2026), sučelja za programiranje aplikacija za upravljanje životnim ciklusom i mogućnosti pretraživanja putovnica za proizvode (EN 18222:2026) te interoperabilnost sustava (EN 18223:2026). Preostale dvije norme, koje obuhvaćaju upravljanje pravima pristupa, sigurnost informacijskog sustava i poslovnu povjerljivost (EN 18239:2026) te autentifikaciju, pouzdanost i cjelovitost podataka (EN 18246:2026), CEN i CENELEC objavili su u rujnu 2026. godine.

dizajnu za održive proizvode predviđa uporabu otvorenih standarda i interoperabilnih formata te prijenos podataka bez ovisnosti o jednom pružatelju usluge (EP i Vijeće EU-a, 2024a). Bitno je naglasiti da se u Službenom listu Europske unije objavljuju upućivanja na navedene usklađene norme, čija primjena osigurava pretpostavku sukladnosti s odgovarajućim zahtjevima Uredbe.

Također, potrebno je uskladiti transparentnost sa zaštitom poslovno osjetljivih informacija kroz jasna pravila razmjene i prava pristupa (Abedi i sur., 2024). Normizacijski okvir DPP-a obuhvaća autentifikaciju, pouzdanost i integritet podataka te njihovu dugoročnu dostupnost (CEN-CENELEC, 2026). Poduzeća stoga trebaju osigurati zaštitu od neovlaštenog pristupa, mogućnost oporavka nakon incidenta i prijenosa podataka drugom pružatelju, a kibernetičku zaštitu mora pratiti sadržajna provjera jer siguran sustav može pohranjivati i netočne podatke.

DPP se može promatrati kao informacijski preduvjet za kružno poslovanje, čiji se doprinos ostvaruje kroz konkretne odluke i procese, a uspješnost implementacije trebalo bi vrednovati prema uporabi podataka, produljenju životnog vijeka proizvoda i rezultatima oporabe materijala, uz usporedbu ostvarenih koristi s troškovima sustava. Procjenu ostvarenih koristi značajno bi olakšao razvoj usporedivih pokazatelja kojima bi se mogli mjeriti učinci DPP-a na sljedivost i transparentnost proizvoda, produljenje njihova životnog vijeka, popravak, ponovnu uporabu, obnovu i oporabu materijala, u odnosu na troškove implementacije i održavanja sustava.

## 5. ZAKLJUČAK

Digitalne putovnice za proizvode mogu predstavljati prekretnicu u prijelazu prema kružnoj ekonomiji jer ne predstavljaju samo digitalizaciju informacija o proizvodu, već uspostavljaju strukturirani podatkovni okvir koji omogućuje različitim sudionicima pristup podacima relevantnima za njihove aktivnosti. Europska unija njihovim uvođenjem povezuje zahtjeve održivosti proizvoda s dostupnošću informacija potrebnih za donošenje odluka tijekom njihova životnog ciklusa. Sljedivost i transparentnost predstavljaju jednu od ključnih poveznica između DPP-a i kružne ekonomije, budući da dostupnost pouzdanih informacija omogućuje učinkovitije očuvanje vrijednosti proizvoda i materijala. Povećanjem transparentnosti i sljedivosti, DPP može unaprijediti učinkovitost lanaca opskrbe, kvalitetu i usklađenost proizvoda,

otvoriti nove mogućnosti za kružnu ekonomiju i zelene proizvode te olakšati standardiziranu digitalnu razmjenu podataka među poduzećima. Koristi se mogu ostvariti i kroz informiranije odluke potrošača, učinkovitiji popravak, ponovnu uporabu i recikliranje te kvalitetniji nadzor tržišta.

Međutim, ostvarenje navedenih koristi ovisi o kvaliteti i ažurnosti podataka, interoperabilnosti sustava te zaštiti poslovno osjetljivih informacija. Financijski i organizacijski zahtjevi implementacije mogu osobito opteretiti mala i srednja poduzeća, zbog čega su izrazito važni dostupna stručna podrška, edukacija i zajednička sektorska rješenja. DPP stoga treba promatrati kao potporu promjenama u proizvodnji i potrošnji, čiji doprinos ovisi o stvarnoj primjeni informacija u poslovnim procesima i odlukama korisnika. Za gospodarske subjekte u Hrvatskoj koji se pripremaju za implementaciju DPP-a preporučuje se pravodobno uspostaviti sustav upravljanja podacima koji će omogućiti sustavno prikupljanje, provjeru, ažuriranje i pohranu podataka potrebnih za DPP te jasno definirati odgovornosti za njihovu kvalitetu i dostupnost. Istodobno, pripremu DPP-ova potrebno je povezati s postojećim poslovnim procesima, osobito procesima nabave, proizvodnje, upravljanja kvalitetom, održavanja, prodaje, odnosno s upravljanjem životnim ciklusom proizvoda, kako bi se njihova implementacija što učinkovitije integrirala u postojeće poslovanje.

Ograničenja rada proizlaze iz činjenice da je regulatorni okvir za DPP još uvijek u razvoju, dok šira primjena putovnica u praksi tek predstoji, zbog čega su empirijski podaci o njihovim stvarnim učincima za sada ograničeni. Stoga se zaključci rada temelje prije svega na regulatornim dokumentima i postojećim teorijskim spoznajama te su usmjereni na potencijalne koristi DPP-a i preduvjete njegove uspješne implementacije. Buduća istraživanja trebala bi pratiti primjenu DPP-a u pojedinim sektorima te usporedivim pokazateljima procijeniti ostvarene okolišne i gospodarske koristi u odnosu na troškove njihova uvođenja i održavanja.

# LITERATURA

Abedi, F., Saari, U. A. i Hakola, L. (2024). Implementation and adoption of digital product passports: A systematic literature review. U *2024 IEEE International Conference on Engineering, Technology, and Innovation (ICE/ITMC).* IEEE. https://doi.org/10.1109/ICE/ITMC61926.2024.10794320

CEN-CENELEC. (2026, 15. srpnja). *Digital product passport, the cornerstone for the implementation of sustainability and circularity on the European Single Market.* https://www.cencenelec.eu/news-events/news/2026/en-in-the-spotlight/2026-07-15-dpp/

Christensen, A., Stingl, V., Omair, M. i Wæhrens, B. V. (2025). Digital product passport in support of data-driven end-of-use strategies–a systems design perspective. *Cleaner Environmental Systems, 19*, 100354. https://doi.org/10.1016/j.cesys.2025.100354

DIGITALEUROPE. (2023, 4. travnja). *The future of eco-design: Necessary conditions for the success of the DPP.* https://www.digitaleurope.org/resources/the-future-of-eco-design-necessary-conditions-for-the-success-of-the-dpp/

European Commission. (2026a, 16. rujna). *DPP registry user guide for economic operators* (verzija 1.03). https://single-market-economy.ec.europa.eu/document/download/079a45e2-469f-4eec-b1e5-32e8e05d1357_en?filename=dpp_registry_user_guide_for_economic_operators.pdf

European Commission. (2026b, 20. srpnja). *The digital product passport registry is now live*. https://single-market-economy.ec.europa.eu/news/digital-product-passport-registry-now-live-2026-07-20_en

European Commission. (b. d.-a). *Digital product passport*. https://single-market-economy.ec.europa.eu/single-market/digital-product-passport_en

European Commission. (b. d.-b). *The digital product passport (DPP) for economic operators.* https://single-market-economy.ec.europa.eu/single-market/digital-product-passport/economic-operators_en

European Commission. (b. d.-c). *The digital product passport (DPP) for consumers*. https://single-market-economy.ec.europa.eu/single-market/digital-product-passport/consumers_en

European Commission. (b. d.-d). *The digital product passport (DPP) for repairers and recyclers*. https://single-market-economy.ec.europa.eu/single-market/digital-product-passport/repairers-and-recyclers_en

European Commission. (b. d.-e). *The digital product passport (DPP) for public authorities*. https://single-market-economy.ec.europa.eu/single-market/digital-product-passport/public-authorities_en

European Union. (b. d.). *Zahtjevi za ekološki dizajn održivih proizvoda.* https://eur-lex.europa.eu/HR/legal-content/summary/ecodesign-requirements-for-sustainable-products.html#keyterm_2

Europska komisija. (2019). *Europski zeleni plan* (COM(2019) 640 final). https://mingo.gov.hr/UserDocsImages//Istaknute%20teme/Zeleni%20plan//Europski%20zeleni%20plan%20HR%20(pdf).pdf

Europska komisija. (2020a). *Novi akcijski plan za kružno gospodarstvo: Za čišću i konkurentniju Europu* (COM(2020) 98 final). https://eur-lex.europa.eu/legal-content/HR/ALL/?uri=CELEX:52020DC0098

Europska komisija. (2020b). *Nova industrijska strategija za Europu* (COM(2020) 102 final). https://eur-lex.europa.eu/legal-content/HR/ALL/?uri=COM:2020:0102:FIN

Europska komisija. (2026). Provedbena uredba Komisije (EU) 2026/1778 o utvrđivanju provedbenih rješenja za registar digitalnih putovnica za proizvode uspostavljen na temelju Uredbe (EU) 2024/1781 Europskog parlamenta i Vijeća. *Službeni list Europske unije, L*, 2026/1778. https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=OJ:L_202601778

Europski parlament i Vijeće Europske unije. (2024a). Uredba (EU) 2024/1781 Europskog parlamenta i Vijeća od 13. lipnja 2024. o uspostavi okvira za utvrđivanje zahtjeva za ekološki dizajn održivih proizvoda, izmjeni Direktive (EU) 2020/1828 i Uredbe (EU) 2023/1542 te stavljanju izvan snage Direktive 2009/125/EZ. *Službeni list Europske unije, L,* 2024/1781. https://eur-lex.europa.eu/eli/reg/2024/1781/oj/hrv

Europski parlament i Vijeće Europske unije. (2024b). Direktiva (EU) 2024/1799 Europskog parlamenta i Vijeća od 13. lipnja 2024. o zajedničkim pravilima za promicanje popravka robe i izmjeni Uredbe (EU) 2017/2394 i direktiva (EU) 2019/771 i (EU) 2020/1828. *Službeni list Europske unije, L*, 2024/1799. https://eur-lex.europa.eu/eli/dir/2024/1799/oj/hrv

Gieß, A. i Möller, F. (2025). Exploring the value ecosystem of digital product passports. *Journal of Industrial Ecology, 29*(2), 561-573. https://doi.org/10.1111/jiec.13621

Legardeur, J. i Ospital, P. (2024). *Digital product passport for the textile sector* (PE 757.808). European Parliamentary Research Service. https://www.europarl.europa.eu/RegData/etudes/STUD/2024/757808/EPRS_STU(2024)757808_EN.pdf

Lyse, S. M. i Huang, L. (2026). Digital product passports: A systematic literature review on framework design and validation. *Digital, 6*(2), 43. https://doi.org/10.3390/digital6020043

Ministarstvo gospodarstva. (2026, 27. kolovoza). *Vlada usvojila Zakon o provedbi Uredbe o ekološkom dizajnu: Hrvatska uspostavlja okvir za održivije proizvode i digitalnu putovnicu proizvoda.* https://mingo.gov.hr/vijesti/vlada-usvojila-zakon-o-provedbi-uredbe-o-ekoloskom-dizajnu-hrvatska-uspostavlja-okvir-za-odrzivije-proizvode-i-digitalnu-putovnicu-proizvoda/10420

Psarommatis, F. i May, G. (2026). A comprehensive review of digital product passports in sustainable manufacturing: Current state, challenges, and future directions. *Circular Economy and Sustainability, 6,* 207. https://doi.org/10.1007/s43615-026-00927-x

Reich, R. H., Ayan, J., Alaerts, L. i Van Acker, K. (2023). Defining the goals of product passports by circular product strategies. *Procedia CIRP, 116*, 257-262. https://doi.org/10.1016/j.procir.2023.02.044

Simões, J., Neves, C., Oliveira, T., Azadi, H. i Goli, I. (2026). Toward circular economy: Investigating citizens' willingness to use digital product passports. *Green Technologies and Sustainability, 4*(3), 100393. https://doi.org/10.1016/j.grets.2026.100393

Trienens, M., Orlowski, V., Schröder, L., Hovemann, A. i Dumitrescu, R. (2025). Information management for the digital product passport: A 150% approach. *Proceedings of the Design Society, 5,* 2093-2100. https://doi.org/10.1017/pds.2025.10223

Vlada Republike Hrvatske. (2026, 27. kolovoza). *Osigurano sedam milijuna eura za naknadu za prijelazno razdoblje usluge osobne asistencije*. https://vlada.gov.hr/osigurano-sedam-milijuna-eura-za-naknadu-za-prijelazno-razdoblje-usluge-osobne-asistencije/47195

Wan, P. K. F. i Jiang, S. (2025). Enabling a dynamic information flow in digital product passports during product use phase: A literature review and proposed framework. *Sustainable Production and Consumption*, 54, 362-374. https://doi.org/10.1016/j.spc.2025.01.014

# DIGITAL PRODUCT PASSPORTS

***Abstract***

*The Digital Product Passport (DPP) is one of the European Union's key instruments for advancing circular economy objectives and the sustainability transition. Under the new regulatory framework, particularly the Ecodesign for Sustainable Products Regulation (ESPR), digital product passports are intended to enable the collection, storage and exchange of information on the origin, composition, sustainability, repair, reuse and recycling of products throughout their life cycle. By increasing transparency and data availability, DPPs can contribute to more efficient resource management, strengthen consumer trust and support new business models based on circular economy principles.*

*This paper aims to examine the concept of digital product passports, which remains unexplored in Croatian academic and professional literature, and analyse their role in the transition towards a circular economy. Particular emphasis is placed on identifying the main expected benefits, challenges and prerequisites for their future implementation, as the adoption of digital product passports will require substantial organisational, technological and data management adjustments by businesses. The study analyses relevant academic and professional literature, the European regulatory framework and strategic documents related to the circular economy and digital transformation.*

*The findings indicate that digital product passports have considerable potential to improve material traceability, support more sustainable decisions by consumers and businesses, and increase the efficiency of reuse, repair and recycling processes. At the same time, the study identifies challenges related to system interoperability, data standardisation, the protection of commercially sensitive information and implementation costs. A limitation of the study arises from the continuing development of the regulatory framework for digital product passports and the fact that their widespread practical application is still forthcoming. Consequently, the study cannot be based on empirical research and experience from actual implementation; instead, assessments of potential impacts draw primarily on regulatory documents and existing theoretical knowledge. The originality of the paper lies in its systematic overview of the digital product passport concept and its integration of regulatory requirements, technological solutions and circular economy objectives. This contributes to an*

*understanding of the regulatory requirements, potential benefits and challenges associated with the future implementation of digital product passports in the Republic of Croatia and the European Union.*

***Keywords:*** *digital product passport, circular economy, sustainable products, traceability, European Union.*

JEL klasifikacija: L26, Q56
Prethodno priopćenje

# MEĐUOVISNOST INDUSTRIJSKE SIMBIOZE I ZELENOG PODUZETNIŠTVA – PRIMJER HRVATSKE

Ivana Unukić*
Rita-Krin Boduljak**
Danijela Ciberlin***
Aleksandar Erceg****

## SAŽETAK

Industrijska simbioza (IS) omogućuje optimizaciju resursa suradnjom između tvrtki iz različitih industrijskih sektora. U kontekstu hrvatskoga gospodarstva, koje se suočava s izazovima niske produktivnosti, ograničenoga inovacijskog kapaciteta i spore transformacije prema održivim poslovnim modelima, IS

* Dr. sc. Ivana Unukić, Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku (e-mail: ivana.unukic@efos.hr).

** Rita-Krin Boduljak, univ. mag. oec., Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku (e-mail: rboduljak@efos.hr).

*** Danijela Ciberlin, univ. spec. oec., German University of Technology in Oman (e-mail: danijela.ciberlin@gutech.edu.om).

**** Prof. dr. sc. Aleksandar Erceg, Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku (e-mail: aleksandar.erceg@efos.hr), korespondirajući autor.

otvara nove mogućnosti za razvoj poduzetništva temeljenog na održivosti i inovacijama. U tom okviru zeleno poduzetništvo zauzima posebno mjesto, povezujući gospodarski rast sa zaštitom okoliša i učinkovitim korištenjem resursa kroz inovativne poslovne modele koji razvijaju kružno gospodarstvo.

Rad proučava vezu između IS-a i zelenog poduzetništva predstavljajući hrvatski primjer poduzetničkog pothvata temeljenog na IS-u. Istraživanje primjenjuje komparativnu analizu sekundarnih podataka o gospodarenju otpadom u državama članicama Europske unije, strukturni pregled akademske literature o zelenom poduzetništvu i IS-u te metodologiju studije slučaja za primjer provedbe zelenog poduzetništva utemeljenog na IS-u. S obzirom na empirijski fokus na Hrvatsku, studija pruža uvid u specifičnosti za tu zemlju, a istodobno prepoznaje da neki zaključci mogu imati ograničenu primjenjivost na širu Europsku uniju.

Rezultati pokazuju da IS može potaknuti razvoj inovativnih poslovnih modela, posebno u sektorima otpada, energetike i poljoprivrede, gdje postoji značajan potencijal za optimizaciju tokova resursa. Ovaj rad doprinosi razumijevanju uloge zelenog poduzetništva u implementaciji IS-a i nudi praktične smjernice za poticanje poduzetničkih ekosustava usmjerenih na održivi gospodarski rast. Originalnost rada ogleda se u povezivanju industrijske simbioze i zelenog poduzetništva kao međusobno ovisnih koncepata koji se u dosadašnjoj literaturi uglavnom analiziraju odvojeno.

**Ključne riječi:** industrijska simbioza, gospodarenje otpadom, zeleno poduzetništvo.

## 1. UVOD

Posljednjih godina gospodarenje otpadom postalo je središnja komponenta prijelaza Europske unije s linearnog na kružno gospodarstvo. Tradicionalni model „uzmi-proizvodi-odbaci“ doveo je do iscrpljivanja resursa, degradacije okoliša i ekonomskih gubitaka (Europski parlament, 2017). U širem ekonomskom kontekstu otpad se više ne promatra kao konačni nusproizvod, već kao sekundarna sirovina koja se može ponovno integrirati u proizvodne procese, doprinoseći gospodarskom rastu, zapošljavanju i razvoju inovativnih poslovnih modela poput industrijske simbioze. Takvi obrasci ukazuju na to da generiranje otpada nije samo ekološki problem već i strukturna značajka gospodarskog razvoja, usko povezana s intenzitetom potrošnje i proizvodnim sustavima. Industrijska simbioza odnosi se na suradnju između tvrtki putem

razmjene materijala, nusproizvoda, energije ili otpada radi poboljšanja učinkovitosti resursa i smanjenja utjecaja na okoliš (Chertow, 2007). Umjesto linearne logike "proizvodnja-potrošnja-zbrinjavanje", uvodi se mrežni model u kojem nusproizvodi, otpadna toplina ili sekundarni materijali cirkuliraju između tvrtki. Posljedično, količina otpada koji se šalje na konačno zbrinjavanje smanjuje se, dok se ukupna učinkovitost resursa povećava.

Analizom empirijskih primjera Chertow (2007) zaključuje da oblici industrijske simbioze koji nastaju postupno, spontanim povezivanjem postojećih industrijskih aktera, pokazuju veću dugoročnu stabilnost od modela uvedenih planiranim, od vrha prema dolje pristupom, poput formalno uspostavljenih eko-industrijskih parkova. Ovaj pristup ističe industrijsku simbiozu kao važan instrument održivoga industrijskog razvoja. U tom kontekstu rad analizira makroekonomske trendove, izazove i razvojni potencijal gospodarenja otpadom u Europskoj uniji, s posebnim naglaskom na Hrvatsku. Analiza temeljena na sekundarnim izvorima, uključujući Eurostat i Europsku agenciju za okoliš (EEA), pokazuje kako poboljšane strategije gospodarenja otpadom mogu potaknuti razvoj zelenog poduzetništva. To je posebno važno za zemlje poput Hrvatske, koje se i dalje suočavaju s ispodprosječnim razinama kružnosti resursa i produktivnosti (Svjetska banka, 2022).

Glavni cilj rada je istražiti potencijal industrijske simbioze u promicanju zelenog poduzetništva u hrvatskom kontekstu. U prva dva odjeljka gospodarenje otpadom istražuje se kao prilika za zeleno poduzetništvo. U sljedećim odjeljcima analizira se studija slučaja hrvatske tvrtke kako bi se pokazalo kako se zeleno poduzetništvo i industrijska simbioza mogu kombinirati. U posljednjem dijelu iznose se zaključci i prijedlozi za daljnja istraživanja.

## 2. GOSPODARENJE OTPADOM KAO PRILIKA – MAKROEKONOMSKI POGLED

Gospodarenje otpadom jedan je od ključnih elemenata tranzicije prema kružnom gospodarstvu, pri čemu se otpad sve više promatra kao resurs koji može potaknuti razvoj novih tržišta, poslovnih modela i poduzetničkih aktivnosti. Makroekonomski pristup omogućuje sagledavanje učinaka sustava gospodarenja otpadom na gospodarski razvoj, učinkovitost korištenja resursa i razvoj industrijske simbioze.

U Europskoj uniji je 2022. godine proizvedeno približno 5 tona otpada po stanovniku, pri čemu je više od 60% obrađenog otpada oporabljeno recikliranjem, ponovnom uporabom i energetskom oporabom. Prosječni stanovnik EU-a tijekom 2023. godine proizveo je 511 kg komunalnog otpada, 177,8 kg ambalažnog otpada i oko 130 kg otpada od hrane godišnje (Eurostat, 2024a). Komunalni otpad čini oko 10% ukupnog otpada u EU-u, a gotovo 48% reciklirano je ili kompostirano tijekom 2023. godine (Eurostat, 2024b). Unatoč napretku, među državama članicama i dalje postoje značajne razlike u učinkovitosti sustava gospodarenja otpadom.

Istraživanje Šverko Grdić i sur. (2020) pokazuje da gospodarski razvijenije zemlje proizvode više komunalnog otpada zbog veće razine potrošnje i gospodarske aktivnosti, ali istodobno ostvaruju više stope recikliranja i oporabe (Slika 1.). Navedeno potvrđuje da učinkoviti sustavi gospodarenja otpadom mogu pridonijeti odvajanju gospodarskog rasta od negativnih okolišnih učinaka.

**Slika 1. Odnos između gospodarskog razvoja i gospodarenja otpadom u EU**

Izvor: prilagođeno prema Šverko Grdić i sur., 2020.

U Hrvatskoj su obrasci nastanka otpada slični europskim trendovima, ali pod snažnim utjecajem niže razine gospodarskog razvoja i manje razvijene

industrijske strukture. Tijekom 2022. godine proizvedeno je oko 7,1 milijun tona otpada (EEA, 2025a), dok količina otpada po stanovniku iznosi približno 1,3 tone godišnje, što je manje od prosjeka EU-a od pet tona (EEA, 2025b). Rast količina otpada povezan je s turističkom potrošnjom, promjenama životnog standarda i nedovoljno razvijenim mjerama sprječavanja nastanka otpada (Svjetska banka, 2022). Iako Hrvatska proizvodi manje komunalnog otpada po stanovniku od europskog prosjeka, više od 60% komunalnog otpada još uvijek završava na odlagalištima, što je znatno iznad cilja EU-a od najviše 10% do 2035. godine (Svjetska banka, 2022). Takva praksa povećava troškove sustava i smanjuje mogućnosti razvoja tržišta sekundarnih sirovina (Stojanović i sur., 2025).

Stope recikliranja i oporabe važan su pokazatelj učinkovitosti korištenja resursa. U EU-u je tijekom 2023. godine reciklirano ili kompostirano 48% komunalnog otpada, dok je stopa recikliranja ambalažnog otpada iznosila oko 65% (Eurostat, 2024b). Zemlje poput Austrije i Njemačke ostvaruju stope recikliranja veće od 60%, ponajprije zahvaljujući razvijenim sustavima proširene odgovornosti proizvođača (Šverko Grdić i sur., 2020). Dodatne koristi ostvaruju se kroz eko-industrijske klastere, pri čemu se nusproizvodi jedne industrije koriste kao resursi druge, primjerice za proizvodnju bioplina, što može smanjiti količine otpada za 20 do 30% (Neves i sur., 2020).

Hrvatska i dalje zaostaje za europskim prosjekom jer je stopa recikliranja komunalnog otpada 2022. godine iznosila između 25 i 30% (EEA, 2025b; Svjetska banka, 2022). Razlozi uključuju nedostatke infrastrukture, fragmentirane sustave prikupljanja otpada i ograničeno sudjelovanje građana (Erceg i sur., 2024). Ipak, segment ambalažnog otpada ostvaruje bolje rezultate, s približno 55% recikliranih količina (Eurostat, 2024b). Ekonomski potencijal povećanja recikliranja je značajan, budući da bi učinkovitija oporaba materijala mogla donijeti između 200 i 500 milijuna eura dodatnih prihoda godišnje (Europski parlament, 2017), dok bi primjena informacijskih tehnologija mogla povećati BDP za 1 do 2% kroz učinkovitije korištenje resursa (Stojanović i sur., 2025).

Važan mehanizam stvaranja gospodarske vrijednosti predstavlja industrijska simbioza, koja omogućuje međusobnu razmjenu materijala, energije i informacija između poduzeća. Prema Akcijskom planu EU-a za kružno gospodarstvo, do 2030. godine očekuje se stvaranje oko 700.000 novih radnih mjesta povezanih s kružnim gospodarstvom i gospodarenjem otpadom (Europski parlament, 2017). Iskustva iz europskih zemalja pokazuju da

zamjena primarnih sirovina sekundarnim resursima može smanjiti troškove poslovanja za 10 do 20% uz istodobno smanjenje emisija (Costa i sur., 2010). Razvoj industrijske simbioze dodatno potiču digitalne platforme koje olakšavaju povezivanje poduzeća i razmjenu informacija o raspoloživim resursima (Pourrahimian i sur., 2026).

U Hrvatskoj, gdje stopa kružnosti iznosi samo 2,7%, u usporedbi s prosjekom EU-a od 12,8%, postoji značajan prostor za napredak (Svjetska banka, 2022). Procjenjuje se da bi ostvarenje ciljeva kružnoga gospodarstva moglo donijeti između jedne i dvije milijarde eura gospodarskih koristi do 2030. godine (Stojanović i sur., 2025). Dodatne mogućnosti otvaraju se kroz digitalno praćenje tokova otpada i razvoj tržišta recikliranih materijala (Unukić, 2025).

Unatoč značajnom potencijalu, razvoj sustava gospodarenja otpadom ograničavaju brojni strukturni izazovi. Niža razina BDP-a po stanovniku u Hrvatskoj u odnosu na prosjek EU-a ograničava ulaganja u infrastrukturu i modernizaciju sustava (EEA, 2025a), dok nedosljedna provedba europskog zakonodavstva dodatno utječe na učinkovitost gospodarenja otpadom (Costa i sur., 2010). Zbog toga su potrebna kontinuirana ulaganja u infrastrukturu, digitalna rješenja, sustave proširene odgovornosti proizvođača i edukaciju dionika (Stojanović i sur., 2025; Sund i sur., 2025).

# 3. ZELENO PODUZETNIŠTVO I INDUSTRIJSKA SIMBIOZA

## 3.1. Zeleno poduzetništvo

Prema Green Project (2012. u Muo i Azeez, 2019), zeleno poduzetništvo obuhvaća aktivnosti koje se svjesno bave ekološkim/društvenim problemima/potrebama kroz provedbu poduzetničkih ideja usred visokih rizika i očekivanja neto pozitivnog utjecaja na okoliš i financijsku održivost. Istraživanja naglašavaju da su zeleni poduzetnici temeljni pokretači održivoga gospodarskog razvoja jer doprinose poboljšanju kvalitete života, posebno u urbanim područjima, i potiču održivi razvoj gradova kao motora nacionalnoga gospodarskog rasta i društvene dobrobiti (Vasilescu i sur., 2023). U tom kontekstu, posebice se ističe uloga poduzetnika u povezivanju ekoloških ciljeva s tržišnim prilikama, osobito u okviru kružnoga gospodarstva. Prema Koirali (2019. u Vasilescu i sur., 2023), zelena mala i srednja poduzeća mogu se podijeliti u tri skupine: eko-inovatori, koji na tržište ulaze s radikalnim i disruptivnim inovacijama; eko-poduzetnici, koji,

slično tradicionalnim poduzetnicima, prepoznaju i iskorištavaju tržišne prilike uz poštivanje ekoloških ciljeva; i eko-usvojitelji, čije se djelovanje prije svega temelji na poštivanju postojećih ekoloških propisa.

Istraživanja u području zelenog poduzetništva ukazuju na razlike u odrednicama između aktivnosti usmjerenih na zelene proizvodne procese i onih usmjerenih na razvoj zelenih proizvoda i usluga, što dodatno naglašava heterogenost zelenih poduzetničkih aktivnosti (Hoogendoorn i sur., 2015, u: Vasilescu i sur., 2023). Sve veću relevantnost zelenog poduzetništva potvrđuje i sve veći naglasak koji kreatori politika stavljaju na zaštitu okoliša i učinkovito korištenje prirodnih i recikliranih resursa.

## 3.2. Zeleno poduzetništvo i industrijska simbioza

U dosadašnjim istraživanjima, zeleno poduzetništvo i industrijska simbioza proučavani su kao odvojena područja. Alka i sur. (2024) prepoznali su taj nedostatak ističući kako su veze između zelenih inovacijskih sustava i načela kružnoga gospodarstva nedovoljno istražene te pozivaju na dodatna istraživanja o ulozi industrijske simbioze. Istraživanja iz različitih zemalja, poput Meksika, Australije i Irana, otkrivaju da zeleni poduzetnici često djeluju kao katalizatori, posrednici i operativni pokretači unutar mreža industrijske simbioze (npr. Zacarías i sur., 2017; Herbst, 2023; Kimuli i sur., 2025). S druge strane, industrijska simbioza pruža strukturni okvir unutar kojeg zeleni poduhvati mogu postići i ekonomsku održivost i ekološki učinak (Nyström i Mirata, 2025; Zacarías i sur., 2017). Kimuli i sur. (2025) ističu da su zeleni poduzetnici unutar mikro, malih i srednjih poduzeća često skriveni agensi koji nesvjesno pokreću i prakticiraju simbiotske razmjene te da djeluju i kao koordinatori i povezivači različitih tokova materijala, znanja i tehnologija.

Veza između zelenog poduzetništva i industrijske simbioze ne pojavljuje se spontano, već zahtijeva specifične pokretače. U istraživanju koju su proveli Mondal i sur. (2023) utvrđeno je da su pokretači temeljeni na tehnologiji i infrastrukturi, zajedno s koordinacijom najvišeg menadžmenta i znanjem zelenih poduzetnika, nužni za postizanje uzajamnog odnosa. Slično tome, Pourrahimian i sur. (2026) ukazuju na ekosustavske platforme i tržnice kao kolaborativnu digitalnu infrastrukturu koja omogućuje industrijsku simbiozu i pruža priliku zelenim poduzetnicima da ponude svoja rješenja.

Herbst (2023) je utvrdila da državni poticaji u obliku financijske potpore i bespovratnih sredstava u Australiji djeluju kao pokretači stvarajući uvjete za mala i srednja poduzeća da povećaju svoje tehnološke sposobnosti kako bi sudjelovala u širim sustavima industrijske ekologije. Olipp i sur. (2026) preporučuju da se vlade usredotoče na pružanje prilika malim i srednjim poduzećima u obliku funkcionalnih platformi za razmjenu njihovih iskustava najbolje prakse u vezi s tranzicijom proizvodnih i logističkih sustava prema kružnom i zelenom gospodarstvu. Takva saznanja potvrđuju da industrijska simbioza i zeleno poduzetništvo nisu odvojeni fenomeni, već međusobno povezani procesi unutar šire tranzicije prema kružnom i suradničkom gospodarstvu. Dokazi dosljedno pokazuju da integracija zelenog poduzetništva i industrijske simbioze zahtijeva promjene i djelovanja vlada u smislu financijskih poticaja, digitalne infrastrukture i kolaborativnih platformi (Slika 2.).

**Slika 2. Zeleno poduzetništvo i industrijska simbioza**

Izvor: autori prema podacima tvrtki.

Prethodna slika pokazuje da neki primjeri pokazuju karakteristike i zelenog poduzetništva i industrijske simbioze (Ecoalf, Toast Ale i Maritimo

Recycling). Nasuprot tome, zeleno poduzetništvo prije svega naglašava korištenje proizvoda i procesa koji ne štete okolišu i doprinose poboljšanju kvalitete života u zajednici (Leaf, Hortiriviera, Tinktura i Include). Ključna razlika između ovih skupina tvrtki je u tome što one koje uključuju industrijsku simbiozu karakterizira recikliranje ili ponovna upotreba materijala, pri čemu otpad ili nusproizvodi služe kao sirovine za proizvodnju novih proizvoda. To dodatno potiče kružno gospodarstvo i učinkovitije korištenje resursa.

Industrijska simbioza potiče tehnološke inovacije za rješavanje ekoloških izazova, primjenjuje perspektivu životnog ciklusa proizvoda te potiče dematerijalizaciju i ekološku učinkovitost kako bi se smanjila potrošnja resursa (Gopalakrishnan i Bakshi, 2018). Na temelju navedenog, očito je da se zeleno poduzetništvo i industrijska simbioza međusobno nadopunjuju, pri čemu potonja pruža konkretan okvir za postizanje ekoloških i ekonomskih ciljeva zelenih poduzetnika

## 4. METODOLOGIJA I OGRANIČENJA

Ovo istraživanje koristi istraživački dizajn koji integrira analizu sekundarnih makroekonomskih podataka i studiju slučaja. Cilj je istražiti potencijal industrijske simbioze za promicanje zelenog poduzetništva u hrvatskom kontekstu.

Istraživanje ima obilježja kvalitativnog preglednog istraživanja temeljeno na triangulaciji izvora podataka. Prikupljeni sekundarni podaci analizirani su metodom deskriptivne i komparativne analize, pri čemu su uspoređeni pokazatelji gospodarenja otpadom i kružnoga gospodarstva u Hrvatskoj i državama članicama Europske unije. Pregled literature proveden je s ciljem identificiranja ključnih teorijskih postavki, pokretača i prepreka povezanih sa zelenim poduzetništvom i industrijskom simbiozom. Studija slučaja tvrtke Gumiimpex-GRP odabrana je kao ilustrativan primjer dobre prakse zbog dugogodišnje primjene principa industrijske simbioze i uspješne komercijalizacije proizvoda nastalih oporabom otpada.

Prva komponenta istraživanja temelji se na sekundarnim podacima o gospodarenju otpadom u državama članicama Europske unije. Službene statističke baze podataka (Eurostat i Europska agencija za okoliš) pružaju pokazatelje poput ukupne i po glavi stanovnika proizvedenog otpada, stopa recikliranja i oporabe, metoda odlaganja te odabranih mjera uspješnosti

kružnoga gospodarstva (Osinska, 2024; Sund i sur., 2025). Ova makro perspektiva daje kontekst za razumijevanje okvirnih uvjeta u kojima nastaju inicijative zelenog poduzetništva i industrijske simbioze.

Druga komponenta obuhvaća studiju slučaja iz Hrvatske koja ilustrira provedbu zelenog poduzetništva utemeljenog na industrijskoj simbiozi. Slučaj se analizira s obzirom na poslovne modele, tokove resursa, upravljačke aranžmane te uočene utjecaje na okoliš i gospodarstvo, kako bi se razumjelo kako se industrijska simbioza operacionalizira na razini poduzeća i regije. Analiza studije slučaja provedena je kroz četiri kriterija: (1) identificiranje ulaznih i izlaznih tokova resursa, (2) utvrđivanje oblika suradnje između dionika uključenih u simbiotsku mrežu, (3) procjenu okolišnih učinaka kroz smanjenje otpada i emisija te (4) identifikaciju poduzetničkih elemenata koji upućuju na stvaranje nove vrijednosti na temelju kružnih poslovnih modela. Takav pristup omogućio je povezivanje teorijskih koncepata zelenog poduzetništva s njihovom praktičnom primjenom.

Zaključci iz studije slučaja koriste se za kontekstualizaciju i ilustraciju makrorazinskih i teorijskih obrazaca, omogućujući trianguliranu procjenu uvjeta, pokretača i prepreka za razvoj zelenog poduzetništva temeljenog na industrijskoj simbiozi u EU i Hrvatskoj. S obzirom na empirijski fokus na Hrvatsku, istraživanje pruža uvide specifične za Hrvatsku, uz prepoznavanje da neki zaključci mogu imati ograničenu primjenjivost na širu Europsku uniju što predstavlja ograničenje ovog istraživanja.

## 5. STUDIJA SLUČAJA INDUSTRIJSKE SIMBIOZE U HRVATSKOJ – GUMIIMPEX VARAŽDIN

Gumiimpex-GRP d.o.o. je vodeći hrvatski proizvođač gumenih i tehničkih proizvoda, specijaliziran za recikliranje otpadnih guma i protektiranje teretnih guma. Glavne djelatnosti uključuju prodaju guma renomiranih marki (Michelin, Goodyear, Bridgestone), proizvodnju preko 7000 gumenih i tehničkih proizvoda godišnje, protektiranje guma NEXT TREAD tehnologijama i usluge popravka guma. Ključna investicija bilo je otvaranje prvoga hrvatskog pogona za recikliranje guma u Slobodnoj zoni Varaždin 2005. godine, koji je kasnije proširen na Trnovec Bartolovečki (Gumiimpex, 2025).

Gumiimpex-GRP d.o.o. primjenjuje principe industrijske simbioze pretvarajući otpadne automobilske gume (od osobnih automobila do traktora i aviona) u resurse putem mehaničkog recikliranja: gume se kidaju, usitnjavaju i odvajaju na granulat, čelik i tekstil, bez emisija ili otpada. Granulat različitih veličina koristi se u građevinarstvu (geotekstili, supstrati), poljoprivredi (supstrati za stoku), sportskim terenima, dječjim igralištima i rehabilitacijskim centrima, čime se sprječava odlaganje otpada na odlagališta i čuvaju prirodni resursi. Ovaj proces, za koji je znanstveno dokazano da je ekološki superiorniji od spaljivanja, podržava kružno gospodarstvo i smanjuje utjecaj na okoliš, omogućujući simbiotske odnose s drugim industrijama (Citycircle, 2020). Tvrtka je prepoznala rastući problem otpadnih guma u Hrvatskoj te regulatorne i društvene pritiske povezane s pitanjima zaštite okoliša. Isti je pretvorila u novi izvor prihoda kroz recikliranje i proizvodnju proizvoda od sekundarnih sirovina (Gumiimpex, 2025; Jahić, 2025) te je pokazala poduzetničke sposobnosti percipirajući "neželjenu" pojavu (nakupljanje otpadnih guma) kao tržišnu priliku, a ne kao trošak. Na taj način, klasični servis i prodaja guma nadopunjuju se novim poslovnim modelom temeljenim na korištenju nusproizvoda i otpada, tipičnom konfiguracijom za prepoznavanje poduzetničkih prilika u kontekstu kružnoga gospodarstva (Erceg i sur., 2025). Gumiimpex, djelujući kao "simbiotsko središte", povezuje različite aktere: dobavljače otpada (servisere, vozne parkove, komunalne usluge) i korisnike sekundarnih sirovina (građevinarstvo, sport i rekreacija, javni sektor) (Jahić, 2025). Ova industrijska simbioza očituje se u (i) tokovima materijala: otpadne gume služe kao ulazna sirovina, dajući gumene granule, ploče, tartan površine, zaštitne premaze za sportske terene, dječja igrališta i industrijske podove (Gumiimpex, 2025); i (ii) prostornim i logističkim vezama: postrojenja za recikliranje i logistička infrastruktura omogućuju lokalno prikupljanje otpada i regionalnu distribuciju proizvoda, smanjujući troškove i emisije povezane s prijevozom (Erceg i sur., 2025; Jahić, 2025). Ključni pokazatelji industrijske simbioze u slučaju Gumiimpexa prikazani su u Tablici 1.

**Tablica 1. Gumiimpex industrijska simbioza**

| Indikator | Vrijednost |
|---|---|
| Tvrtke | 1 jezgra + više stranaka (sakupljači guma, građevinske tvrtke, općine) |
| Simbiotski tokovi | 3 glavna toka (otpadne gume → gumeni granulat → građevinski proizvodi) |
| Uštede $CO_2$ | 15.000–22.500 t/god. |
| Financijski | 75–100 milijuna eura prihoda (2024); naknade za prikupljanje/obradu guma |

Izvor: prilagođeno prema Infobiz, 2025; Gumiimpex, 2025.

Gumiimpexov ulazak u recikliranje guma i razvoj proizvoda od recikliranih materijala u biti su u skladu s definicijama zelenog poduzetništva, u kojima: (1) problem okoliša je polazište poslovne ideje i (2) korist za okoliš integrirana je u srž poslovnog modela, a ne samo u marketinške aktivnosti (Melay i Kraus, 2012). U širem kontekstu hrvatske i europske politike kružnoga gospodarstva, Gumiimpex se može promatrati kao konkretan primjer tvrtke koja operacionalizira ciljeve zelenog poduzetništva kroz industrijsku simbiozu – prepoznaje regulatorne, tehnološke i društvene promjene kao priliku, ulaže u inovativnu infrastrukturu i gradi novi tržišni segment temeljen na recikliranim resursima umjesto linearne potrošnje (Citycircle, 2020).

## 6. ZAKLJUČAK

Gospodarenje otpadom predstavlja važan gospodarski potencijal za Europsku uniju i Hrvatsku. Povećanje stopa recikliranja, razvoj tržišta sekundarnih sirovina i jačanje industrijske simbioze mogu pridonijeti smanjenju okolišnih opterećenja, povećanju konkurentnosti i razvoju novih poslovnih modela. Uspješna tranzicija prema kružnom gospodarstvu zahtijeva istodobne promjene u poslovnim modelima, institucionalnim okvirima i ponašanju potrošača (Geissdoerfer i sur., 2017). Iako je Europska unija postigla značajan napredak u recikliranju i oporabi resursa, i dalje postoje velike razlike među državama članicama, osobito u zemljama poput Hrvatske, gdje su stope kružnosti ispod prosjeka EU. Istodobno, tokovi otpada predstavljaju nedovoljno iskorišten gospodarski resurs koji može potaknuti industrijsku simbiozu, zeleno poduzetništvo i razvoj tržišta sekundarnih sirovina. Jačanje

institucionalnog okvira, poboljšanje provedbe politika i ulaganje u moderne sustave gospodarenja otpadom mogli bi značajno unaprijediti ekonomsku učinkovitost i ekološku održivost.

Zeleno poduzetništvo odnosi se na aktivnosti koje rješavaju ekološke i društvene izazove, a istodobno osiguravaju ekološku i financijsku održivost. U tom kontekstu, zeleni poduzetnici doprinose zaštiti okoliša kroz održive proizvode, usluge i poslovne prakse te se mogu klasificirati kao eko-inovatori, eko-poduzetnici ili eko-usvojitelji. Industrijska simbioza predstavlja praktičan mehanizam za provedbu načela zelenog poduzetništva kroz suradnju i ponovnu upotrebu otpada ili nusproizvoda kao proizvodnih resursa.

Analiza studije slučaja pokazuje da industrijska simbioza može potaknuti razvoj inovativnih poslovnih modela, posebno u sektorima otpada i energetike, gdje postoji značajan potencijal za optimizaciju tokova resursa. Istraživanje je pokazalo povezanost industrijske simbioze i zelenog poduzetništva, ali i da nije svaka industrijska simbioza oblik zelenog poduzetništva.

Doprinos ovog rada ogleda se u povezivanju dvaju koncepata koji se u dosadašnjoj literaturi najčešće analiziraju odvojeno. Rad pokazuje da industrijska simbioza može predstavljati operativni mehanizam zelenog poduzetništva te da zeleni poduzetnici mogu imati ulogu inicijatora, koordinatora i nositelja simbiotskih procesa. Time se proširuje razumijevanje međuovisnosti industrijske simbioze i zelenog poduzetništva te se pruža konceptualni okvir za buduća empirijska istraživanja.

U hrvatskom gospodarstvu postoji značajan prostor za jačanje sinergije između ovih koncepata, osobito u sektorima poput cementne industrije (npr. Holcim Hrvatska), energetike (HEP i Holcim Hrvatska), poljoprivrede, drvne industrije i gospodarenja otpadom (kao u proučavanom slučaju). Industrijska simbioza omogućuje poduzećima da otpad i nusproizvode pretvore u vrijedne resurse, dok zeleni poduzetnici prepoznaju poslovne prilike u razvoju inovativnih proizvoda i usluga utemeljenih na takvim resursima. Time se istodobno povećava konkurentnost poduzeća i smanjuje opterećenje okoliša. Posebno je važno što Hrvatska raspolaže značajnim količinama biomase, građevinskog otpada i industrijskih nusproizvoda koji još uvijek nisu u potpunosti iskorišteni. Razvojem mreža industrijske simbioze otvara se mogućnost stvaranja novih zelenih poduzeća koja bi se bavila oporabom,

preradom i ponovnom uporabom tih materijala. Time se stvaraju nova radna mjesta, potiču inovacije i povećava regionalna gospodarska otpornost.

Iz perspektive javnih politika, rezultati istraživanja upućuju na potrebu jačeg institucionalnog poticanja industrijske simbioze kroz financijske potpore, razvoj digitalnih platformi za razmjenu nusproizvoda i sekundarnih sirovina te sustavniju suradnju između poduzeća, lokalne samouprave i znanstveno-istraživačkih institucija. Za poduzetnike rezultati potvrđuju da izazovi povezani s otpadom i učinkovitim korištenjem resursa mogu predstavljati izvor novih poslovnih prilika i konkurentskih prednosti.

Sinergija industrijske simbioze i zelenog poduzetništva može pridonijeti ostvarivanju ciljeva Europskoga zelenog plana. U tom kontekstu industrijska simbioza može postati operativni alat, a zeleno poduzetništvo pokretačka snaga održivih inovacija. Buduća istraživanja trebala bi uključiti veći broj studija slučaja iz različitih sektora gospodarstva te primjenu kvantitativnih metoda kojima bi se mjerio doprinos industrijske simbioze konkurentnosti poduzeća, otvaranju novih radnih mjesta i ostvarivanju okolišnih ciljeva. Također bi bilo korisno usporediti iskustva Hrvatske s drugim državama članicama Europske unije kako bi se identificirali najučinkovitiji modeli razvoja zelenog poduzetništva temeljenog na industrijskoj simbiozi.

## ZAHVALE

Ovo je istraživanje rezultat projekta **SIDRO – Sinergija dionika za razvoj održivog poduzetničkog društva, koji financira Europska unija – NextGenerationEU**. Izneseni stavovi i mišljenja isključivo su stavovi autora/autorica i ne odražavaju nužno stavove Europske unije ili Europske komisije. Ni Europska unija ni Europska komisija ne mogu se smatrati odgovornima za njih.

## REFERENCE

Alka, T. A., Raman, R. i Suresh, M. (2024). Research trends in innovation ecosystem and circular economy. *Discover Sustainability*, *5*(1), 323.

Cárcamo, E. A. B. i Peñabaena-Niebles, R. (2022). Opportunities and challenges for the waste management in emerging and frontier countries through industrial symbiosis. *Journal of Cleaner Production*, 363, 132607.

Chertow, M. R. (2007). Uncovering" industrial symbiosis. *Journal of Industrial Ecology*, *11*(1), 11-30. https://doi.org/10.1162/jiec.2007.1110

CityCircle (2020). Citycircle. Preuzeto: https://programme2014-20.interreg-central.eu/Content.Node/CITYCIRCLE.html

Costa, I., Massard, G. i Agarwal, A. (2010). Waste management policies for industrial symbiosis development: case studies in European countries. *Journal of Cleaner Production*, *18*(8), 815-822. https://doi.org/10.1016/j.jclepro.2009.12.019

ECOALF (nd). Ecoalf. Preuzeto: https://ecoalf.com/en?srsltid=AfmBOop8JTJelNpYhVFIrVJNbzA-Uzr7Cc47qMg-w6zTjS1_re6kU422

EEA (2025a). Total waste generation. Croatia. Europe's environment 2025. European Environment Agency. Preuzeto: https://www.eea.europa.eu/en/europe-environment-2025/countries/croatia/waste-generation

EEA (2025b). Hrvatska – Croatia – Municipal waste factsheet 2025. European Environment Agency. Preuzeto: https://www.eea.europa.eu/en/topics/in-depth/waste-and-recycling/municipal-and-packaging-waste-management-country-profiles-2025/hr-municipal-waste-factsheet.pdf

Erceg, A., Krzeminski, P., Jonaitiene, V., Munoz Marti, M., Dunjić, B., Szilagyi, A., Burmaoglu, S., Činčurak Erceg, B., Giacomi, E., Anastasovski, A., Ryan, Y., Skolou, V., Chrabak, P., Refalo, P., Borg, M., Dosoretz, C., Plaza, J.P., Hurtado Ruiz, A.M., Özcan Kilcan, C., Tkaczyk, A.H., Godina, R. i Neves, A., (2024). *State-of-the-art report on Industrial Symbiosis topic and its different sub-areas (settling the basis for further improvements and their introduction in the industry)*. Yecla: CETEM.

Erceg, A., Sannegadu, R., Damoska Sekuloska, J., Činčurak Erceg, B., Uppiah, M.V. i Anastasovski, A. (2025). Croatia, North Macedonia and Mauritius – Industrial Symbiosis barriers comparison. U *Proceedings of WG2*

*Workshop & Conference-Industrial Symbiosis from a business perspective: challenges and opportunities* (str. 7-21). CETEM

Europski parlament (2017). Towards a circular economy – Waste management in the EU. European Parliamentary Research Service. Preuzeto: https://www.europarl.europa.eu/RegData/etudes/STUD/2017/581913/EPRS_STU(2017)581913_EN.pdf

Eurostat (2024a). Waste statistics. European Commission. Preuzeto: https://ec.europa.eu/eurostat/statistics-explained/index.php/Waste_statistics

Eurostat (2024b). Municipal waste statistics. European Commission. Preuzeto: https://ec.europa.eu/eurostat/statistics-explained/index.php/Municipal_waste_statistics

Geissdoerfer, M., Savaget, P., Bocken, N. M. i Hultink, E. J. (2017). The Circular Economy – A new sustainability paradigm? J*ournal of cleaner production*, 143, 757-768.

Gopalakrishnan, V. i Bakshi, B.R. (2018). Ecosystems as unit operations for local techno-ecological synergy: Integrated process design with treatment wetlands. *AIChE Journal*, *64*(7), 2390-2407. https://doi.org/10.1002/aic.16093

Gumiimpex-GRP (2025). O nama. Dostupno na https://gumiimpex.com/ pristup 4. siječnja 2026.

Herbst, J. M. (2023). Transforming Trash into Treasure Troves: SMEs Co-Create Industrial Ecology Ecosystems with Government. *Sustainability*, 15(19), 14533.

Hortiriviera (N/A). Pero. Preuzeto: https://www.pero.bio/

Include (N/A). About Include. Preuzeto: https://include.eu/

Infobiz-Fina (2025). Gumiimpex-grp. Preuzeto: https://infobiz.fina.hr/tvrtka/gumiimpex-grp-doo/OIB-82298562620

Jahić, N. (2025). Gumiimpex-GRP – From a Small Tyre Repair Shop to a Regional Tyre Recycling Leader. Preuzeto: https://www.tyreandrubberrecycling.com/articles/news/regional-news/gumiimpex-grp-from-a-small-tyre-repair-shop-to-a-regional-tyre-recycling-leader/

Kimuli, S. N. L., Sendawula, K., Najjinda, S. i Nakimuli, N. K. (2025). The potential of industrial symbiosis in fostering sustainable entrepreneurship

among the micro and small enterprises (MSEs): evidence from a developing country. *Journal of Work-Applied Management*, *17*(1), 147-159. https://doi.org/10.1108/JWAM-07-2023-0073

Koirala, S. (2019). *SMEs: Key drivers of green and inclusive growth.* OECD Green Growth Papers, 2019(03).

LEAF (N/A). Vijesti. Preuzeto: https://leaf.eco/leafmarque/news/logo

Livit (2025). O nama. Preuzeto: https://www.livit.hr/

Maritimo recikliranje (N/A). Maritimo. Preuzeto: https://maritimo-recycling.com/

Melay, I. i Kraus, S. (2012). Green entrepreneurship: Definitions of related concepts. *International Journal of Strategic Management*, *12*(2), 1-12.

Mondal, S., Singh, S. i Gupta, H. (2023). Green entrepreneurship and digitalization enabling the circular economy through sustainable waste management – An exploratory study of emerging economy. *Journal of Cleaner Production*, 422, 138433.

Muo, I. i Azeez, A.A. (2019). Green entrepreneurship: Literature review and agenda for future research. *International Journal of Entrepreneurial Knowledge*, *7*(2).

Neves, A., Godina, R., Azevedo, S.G. i Matias, J.C. (2020). A comprehensive review of industrial symbiosis. *Journal of Cleaner Production*, 247, 119113.

Nyström, K., i Mirata, M. (2025). How Companies With Industrial Symbiosis Business Models Can Contribute to the Mainstreaming of Industrial Symbiosis. *Business Strategy and the Environment*, *34*(6), 7656-7673. https://doi.org/10.1002/bse.4363

Olipp, N., Jöbstl, L. i Woschank, M. (2026). Factors of success and challenges of the transformation of the production and logistics system from a linear to a circular model in Austrian small and medium-sized enterprises. *Cogent Engineering*, *13*(1), 2599578.

Osińska, M. (2024). The determinants of municipal solid waste management efficiency in EU countries. *Economics and Environment*, *88*(1), 637.

Pourrahimian, P., Seyedzadeh, S., Arabi, B., Kahani, D. i Lotfian, S. (2026). Digital Enablers of the Circular Economy: A Systematic Review of

Applications, Barriers, and Future Directions. *Journal of Manufacturing and Materials Processing*, *10*(4).

Stojanović, A., Milošević, D., Shapkova Kocevska, K. i Puche, J. (2025). The position of European countries regarding opportunities for Industrial Symbiosis: A comparative analysis employing multi-criteria decision-making. *Proceedings of 23rd International Conference on Management, Enterprise*, Benchmarking. Proceedings I. (MEB 2025), Budapest, April 4, 2025, str. 5-16.

Sund, J., Albizzati, P., Scheutz, C. i Tonini, D. (2025). Comprehensive assessment of environmental and economic impacts of the entire EU waste management system. *Waste Management*, 204, 114910. https://doi.org/10.1016/j.wasman.2025.114910

Svjetska banka (2022.). *Croatia Circular Economy Approaches in Solid Waste Management: Diagnostic Analysis*. The World Bank. Preuzeto: https://thedocs.worldbank.org/en/doc/82f33c35b99510f0162e26da46efc97e-0080012022/original/Circular-Economy-Diagnostic-Analysis.pdf

Šverko Grdić, Z., Krstinić Nižić, M. i Rudan, E. (2020). Circular economy concept in the context of economic development in EU countries. *Sustainability*, *12*(7), 3060.

Tinktura (nd). O nama. Preuzeto: https://www.tinktura.com

TOAST ALE (nd). O nama. Preuzeto: https://www.toastbrewing.com/

Unukić, I. (2025). Bridging Traditional and Digital Industrial Symbiosis: Comparative Insights From Croatia and Slovenia in the ESG and Digital Transformation Era. U 9th FEB International Scientific Conference: Sustainable Management in the Age of ESG and AI: Navigating Challenges and Opportunities (str. 145-156). Maribor: Sveučilište u Mariboru.

Vasilescu, M. D., Dimian, G. C. i Gradinaru, G. I. (2023). Green entrepreneurship in challenging times: a quantitative approach for European countries. *Economic research – Ekonomska istraživanja*, *36*(1), 1828-1847.

Zacarías, M. A. V., Aguiñaga, E. i Lagunas, E. A. (2017). Sustainable entrepreneurship in industrial ecology: the cheese case in Mexico. *International Journal of Trade and Global Markets*, *10*(1), 19-27.

# THE INTERDEPENDENCE OF INDUSTRIAL SYMBIOSIS AND GREEN ENTREPRENEURSHIP – THE EXAMPLE OF CROATIA

***Abstract***

*Industrial symbiosis (IS) enables the optimization of resources through cooperation between companies from different industrial sectors. In the context of the Croatian economy, which faces challenges of low productivity, limited innovation capacity and slow transformation towards sustainable business models, IS opens new opportunities for the development of sustainable, innovation-based entrepreneurship. In this framework, green entrepreneurship occupies a special place, linking economic growth with environmental protection and efficient use of resources through innovative business models that develop a circular economy.*

*The paper examines the link between IS and green entrepreneurship by presenting a Croatian example of an IS-based entrepreneurial venture. The research applies a comparative analysis of secondary data on waste management across European Union member states, a structural review of the academic literature on green entrepreneurship and IS, and a case study methodology to illustrate the implementation of green entrepreneurship based on IS. Given the empirical focus on Croatia, the study provides insight into the specificities of that country while recognizing that some conclusions may have limited applicability to the wider European Union.*

*The results show that IS can stimulate the development of innovative business models, especially in the waste, energy and agriculture sectors, where there is significant potential for optimizing resource flows. This paper contributes to the understanding of the role of green entrepreneurship in IS implementation and offers practical guidelines for fostering entrepreneurial ecosystems focused on sustainable economic growth. The originality of the paper lies in linking industrial symbiosis and green entrepreneurship as interdependent concepts that have largely been analyzed separately in existing literature.*

***Keywords:*** *industrial symbiosis, waste management, green entrepreneurship.*

JEL klasifikacija: M10, O31, Q56, C38

Izvorni znanstveni rad

# IMPLEMENTACIJA KRUŽNIH POSLOVNIH MODELA U HRVATSKIM INDUSTRIJSKIM PODUZEĆIMA: ULOGA INOVATIVNOSTI I VLADINE POTPORE

Umihana Umihanić Bukvić*

Lana Cindrić**

## SAŽETAK

Prijelaz na kružno gospodarstvo zahtijeva od poduzeća razvoj i implementaciju poslovnih modela koji istodobno pridonose održivosti, inovativnosti i dugoročnoj konkurentnosti. Cilj rada jest ispitati povezanost inovativnosti poduzeća i njezinih dimenzija s implementacijom kružnih poslovnih modela u hrvatskim industrijskim poduzećima te utvrditi moderira li vladina potpora navedeni odnos. Empirijsko istraživanje provedeno je anketnim upitnikom na uzorku od 306 poduzeća iz područja djelatnosti B–F s najmanje deset zaposlenih, od kojih je 271 zadržano u analizi. Mjerni modeli provjereni su konfirmatornom faktorskom analizom, konceptualni model

* Dr. sc. Umihana Umihanić Bukvić, direktorica Laurus Company d.o.o. (e-mail: uumihanic@net.efzg.hr), korespondirajući autor.

** Dr. sc. Lana Cindrić, Sveučilište u Zagrebu, Ekonomski fakultet, Katedra za organizaciju i menadžment (e-mail: lcindric@efzg.hr).

testiran je modeliranjem strukturnih jednadžbi temeljenim na kovarijancama (engl. Covariance-Based Structural Equation Modeling, CB-SEM), a moderirajući učinak moderiranom regresijskom analizom uz bootstrap postupak. Rezultati potvrđuju da inovativnost poduzeća ostvaruje snažan, pozitivan i statistički značajan utjecaj na implementaciju kružnih poslovnih modela, pri čemu se kao najstabilniji pokretači izdvajaju inovacije proizvoda i organizacijske inovacije. Vladina potpora ne moderira značajno odnos ukupne inovativnosti i implementacije kružnih poslovnih modela, ali jača učinak inovacija proizvoda, koji je gotovo dvostruko izraženiji u poduzećima s višom razinom vladinih poticaja. Rezultati upućuju na važnost istodobnog razvoja organizacijskih sposobnosti i ciljane institucionalne potpore te imaju implikacije za menadžere i kreatore javnih politika. Ograničenja proizlaze iz presječnog dizajna, perceptivnih mjera prikupljenih od jednog ispitanika i usmjerenosti na hrvatska industrijska poduzeća. Znanstveni doprinos očituje se u empirijskom ispitivanju odnosa između vrsta inovacija, vladine potpore i tipova kružnih poslovnih modela u hrvatskom kontekstu, čime se proširuju spoznaje o organizacijskim i institucionalnim čimbenicima kružne tranzicije.

**Ključne riječi:** kružno gospodarstvo, kružni poslovni modeli, inovativnost poduzeća, vladina potpora, modeliranje strukturnih jednadžbi.

# 1. UVODNA RAZMATRANJA

Linearna logika poslovanja sve se teže usklađuje s ograničenošću resursa, kolebanjem cijena sirovina i sve strožim regulatornim zahtjevima Europske unije. Na razini poduzeća alternativa se operacionalizira putem kružnih poslovnih modela, koji ne predstavljaju tehničku doradu postojećih procesa, nego preoblikovanje logike stvaranja, isporuke i zahvaćanja vrijednosti (Teece, 2010; Geissdoerfer, Vladimirova i Evans, 2018; Centobelli, Cerchione, Chiaroni, Del Vecchio i Urbinati, 2020).

Hrvatska djeluje unutar razmjerno razvijenoga regulatornog okvira kružnoga gospodarstva, no pomaci u poslovnom sektoru i dalje su skromni. Stopa kružne uporabe materijala iznosila je 6,2 % u 2023. godini, u odnosu na prosjek Europske unije od 11,8 % (Eurostat, 2025), a izrada Nacionalnog plana razvoja kružnog gospodarstva za razdoblje od 2026. do 2032. pokrenuta je tek 2025. godine (Ministarstvo gospodarstva Republike Hrvatske, 2025). Kružne prakse u hrvatskim poduzećima uvode se neravnomjerno, uz

ograničena znanja i nedovoljno stabilne provedbene mehanizme (Andabaka, Beg i Gelo, 2018; Lovrenčić Butković i Mihaljević, 2021).

Literatura inovativnost prepoznaje kao ključan unutarnji pokretač kružnih poslovnih modela (Bocken, de Pauw, Bakker i van der Grinten, 2016; Kuzma i Sehnem, 2023), a vladine poticaje kao kontekst koji može olakšati prevođenje inovacija u kružne prakse (Rehman, Al-Ghazali i Farook, 2022). Ipak, istraživanja inovativnost najčešće tretiraju kao jedinstven konstrukt, a nalazi pretežito potječu iz institucionalno zrelijih gospodarstava (Khan, Daddi i Iraldo, 2020).

Cilj rada jest ispitati povezanost inovativnosti poduzeća i njezinih dimenzija s implementacijom kružnih poslovnih modela (KPM) u hrvatskim industrijskim poduzećima te utvrditi moderira li vladina potpora taj odnos. Podaci potječu iz šireg istraživanja provedenog u okviru doktorskog rada jedne od autorica (Umihanić, 2026), no konceptualni model, pročišćavanje mjernih ljestvica i analize su izvorni. Doprinos rada je trostruk: ispituju se neto učinci četiriju vrsta inovacija na četiri tipa KPM-a; vladina potpora uvodi se kao moderator, a ne samo kao izravna odrednica; a dokazi dolaze iz posttranzicijskoga gospodarstva članice Europske unije, uz provjeru pristranosti zajedničke metode i robusnosti nalaza.

# 2. TEORIJSKI OKVIR I RAZVOJ HIPOTEZA

## 2.1. Kružni poslovni modeli

Kružni poslovni model preoblikuje arhitekturu stvaranja i zahvaćanja vrijednosti u skladu s načelima zatvaranja, usporavanja, intenziviranja i dematerijalizacije tokova resursa (Bocken i sur., 2016). Tipologija Geissdoerfera, Pieronija, Pigossa i Soufanija (2020) razlikuje modele recikliranja resursa (povratak materijala u proizvodne cikluse), produljenja vijeka trajanja (dugotrajan dizajn, servis i nadogradnja), intenziviranja uporabe (dijeljenje i zajedničko korištenje imovine) i dematerijalizacije (zamjena materijalnih rješenja uslugama i digitalnim rješenjima). Budući da dijele logiku očuvanja vrijednosti resursa, u radu se promatraju kao dimenzije jedinstvenog konstrukta implementacije KPM-a.

## 2.2. Inovativnost poduzeća kao pokretač implementacije kružnih poslovnih modela

Prema resursno utemeljenom pristupu i teoriji dinamičkih sposobnosti, prednost proizlazi iz sposobnosti stalnog kombiniranja i preoblikovanja resursa (Barney, 1991; Teece, 2007), a inovativnost je izraz upravo te sposobnosti. Slijedeći Oslo priručnik (OECD, 2018), razlikuju se četiri vrste inovacija. Inovacije proizvoda određuju trajnost i materijalnu intenzivnost ponude (Chioatto, Zecca i D'Amato, 2020); procesne inovacije mijenjaju tokove materijala i omogućuju povratne tokove; organizacijske inovacije stvaraju rutine i kulturu u kojima se kružne inicijative ukorjenjuju (Camisón i Villar-López, 2014); a marketinške inovacije kružnu ponudu čine prihvatljivom kupcima (Sehnem, de Queiroz, Pereira, dos Santos Correia i Kuzma, 2022). Empirijski nalazi uglavnom potvrđuju pozitivnu vezu inovativnosti i kružnih praksi (Kuzma i Sehnem, 2023; Brogi i Menichini, 2024), uz upozorenje da se generička inovativnost ne prelijeva automatski u kružne inovacije (Dangelico i Pujari, 2010; De Jesus i Mendonça, 2018). Stoga se postavljaju sljedeće hipoteze:

**H1: Inovativnost poduzeća pozitivno utječe na implementaciju kružnih poslovnih modela.**

H1a – H1d: Inovacije proizvoda (H1a), procesa (H1b), organizacijske (H1c) i marketinške inovacije (H1d) pozitivno utječu na implementaciju kružnih poslovnih modela.

## 2.3. Vladina potpora kao moderator

Prevođenje inovacija u kružne poslovne modele uključuje visoke početne troškove i neizvjesnost, pa poduzeća, osobito mala i srednja, ovise o vanjskoj potpori (Rizos i sur., 2016; García-Quevedo, Jové-Llopis i Martínez-Ros, 2020). Vladina potpora u radu obuhvaća povoljno financiranje projekata smanjenja otpada, partnerstva s javnim akterima i programe edukacije koje podupire država. Takvi instrumenti smanjuju rizik ulaganja i šalju signal da će kružna rješenja biti vrednovana (Horbach, Rammer i Rennings, 2012). Rehman i suradnici (2022) pokazuju da vladini poticaji jačaju vezu kružnih inovacija i inovacija poslovnoga modela, no u okruženjima fragmentiranih politika takvi učinci ostaju ograničeni (Kirchherr i sur., 2018). Konceptualni model prikazan je na slici 1.

**H2: Vladina potpora pozitivno moderira odnos između inovativnosti poduzeća i implementacije kružnih poslovnih modela.**

**Slika 1. Konceptualni model istraživanja**

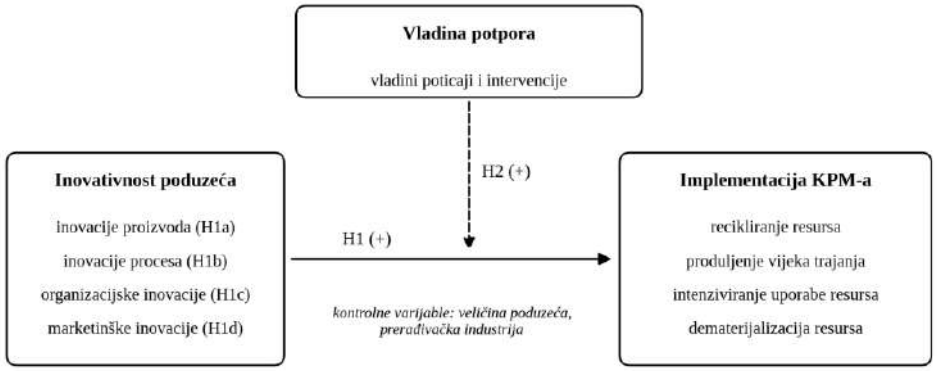


Izvor: izrada autorica.

# 3. METODOLOGIJA ISTRAŽIVANJA

## 3.1. Uzorak i mjerni instrument

Populaciju čine aktivna poduzeća iz područja djelatnosti B–F (NKD 2007) s najmanje deset zaposlenih. Podaci su prikupljeni online upitnikom od ožujka do srpnja 2025. godine od direktora i drugih članova menadžmenta, na temelju kontaktne baze poduzeća Dun & Bradstreet. Prikupljeno je 306 valjanih upitnika: prerađivačka industrija čini 53,6 % uzorka, građevinarstvo 22,5 %, gospodarenje vodom i otpadom 12,7 %, opskrba energijom 10,1 %, a rudarstvo 1,0 %; poduzeća s do 50 zaposlenih čine 59,5 %, a s više od 250 zaposlenih 11,8 % uzorka. Nedostajući odgovori (19 od 33.660) zamijenjeni su aritmetičkom sredinom, a na temelju Mahalanobisove udaljenosti ($p \leq 0{,}001$) isključeno je 35 atipičnih opažanja, pa glavne analize počivaju na 271 poduzeću.

Tvrdnje su mjerene petostupanjskom Likertovom ljestvicom. Instrument se temelji na validiranim ljestvicama, prevedenim postupkom povratnog prevođenja i provjerenim od panela dvaju menadžera i četiriju članova akademske zajednice. Inovativnost je mjerena s 22 tvrdnje prema Kuzmi i

Sehnemu (2022), implementacija KPM-a s 33 tvrdnje prema tipologiji Geissdoerfera i suradnika (2020) i indikatorima Kuzme i Sehnema (2022) te Kristoffersena, Mikalefa, Blomsme i Lija (2021), a vladina potpora sa šest tvrdnji prema Rehmanu i suradnicima (2022). Unaprijed su isključene dvije sadržajno neprikladne tvrdnje: tvrdnja o proizvodima koji olakšavaju prijelaz na kružnu ekonomiju, jer opisuje zavisnu varijablu, i tvrdnja o recikliranju „neovisno o EU fondovima“ jer ne opisuje vladinu potporu.

## 3.2. Postupak analize podataka

Mjerni model provjeren je konfirmatornom faktorskom analizom (CFA) s devet koreliranih faktora, metodom najveće vjerodostojnosti. Čestice s niskim opterećenjima ili izraženim rezidualnim kovarijancama uklanjane su postupno, uz najmanje tri indikatora po dimenziji. Pouzdanost je procijenjena Cronbachovim alfa i kompozitnom pouzdanošću (CR), konvergentna valjanost prosječnom izlučenom varijancom (AVE), a diskriminantna valjanost Fornell-Larckerovim kriterijem i HTMT omjerom (Fornell i Larcker, 1981; Henseler, Ringle i Sarstedt, 2015). Pristranost zajedničke metode ispitana je Harmanovim testom i latentnim metodskim faktorom (Podsakoff, MacKenzie, Lee i Podsakoff, 2003).

Hipoteze H1 – H1d testirane su modeliranjem strukturnih jednadžbi: u modelu A inovativnost i KPM specificirani su kao konstrukti drugog reda, u modelu B četiri vrste inovacija istodobno predviđaju KPM, a model C ispituje veze vrsta inovacija s pojedinim tipovima KPM-a. Kontrolirane su veličina poduzeća i pripadnost prerađivačkoj industriji. Hipoteza H2 testirana je moderiranom regresijskom analizom (Hayes, 2018) na kompozitnim mjerama, uz centriranje prediktora, standardne pogreške HC3 i bootstrap s 5.000 uzoraka. Analize su provedene u programskom jeziku Python (NumPy i SciPy).

# 4. REZULTATI ISTRAŽIVANJA

## 4.1. Mjerni model

Nakon pročišćavanja svaka dimenzija zadržala je tri indikatora, osim recikliranja resursa, koje je zadržalo pet (tablica 1.).

**Tablica 1. Pouzdanost, konvergentna valjanost i deskriptivni pokazatelji dimenzija (n = 271)**

| Dimenzija | k | λ (raspon) | α | CR | AVE | M | SD |
|---|---|---|---|---|---|---|---|
| ***Inovativnost poduzeća*** | | | | | | | |
| Inovacije proizvoda | 3 | 0,776–0,942 | 0,895 | 0,899 | 0,749 | 3,90 | 1,03 |
| Inovacije procesa | 3 | 0,699–0,784 | 0,772 | 0,776 | 0,537 | 3,89 | 0,73 |
| Organizacijske inovacije | 3 | 0,826–0,862 | 0,884 | 0,884 | 0,719 | 3,82 | 0,85 |
| Marketinške inovacije | 3 | 0,735–0,814 | 0,818 | 0,819 | 0,601 | 3,43 | 0,81 |
| ***Implementacija kružnih poslovnih modela (KPM)*** | | | | | | | |
| Recikliranje resursa | 5 | 0,655–0,878 | 0,894 | 0,895 | 0,633 | 4,00 | 0,77 |
| Produljenje vijeka trajanja | 3 | 0,751–0,933 | 0,894 | 0,891 | 0,734 | 3,62 | 0,96 |
| Intenziviranje uporabe resursa | 3 | 0,634–0,785 | 0,743 | 0,753 | 0,506 | 3,45 | 0,78 |
| Dematerijalizacija resursa | 3 | 0,846–0,872 | 0,893 | 0,896 | 0,741 | 3,21 | 1,11 |
| ***Vladina potpora*** | | | | | | | |
| Vladini poticaji i intervencije | 3 | 0,734–0,901 | 0,850 | 0,860 | 0,674 | 3,26 | 1,05 |

Izvor: izrada autorica. Napomena: k – broj zadržanih čestica; λ – standardizirana faktorska opterećenja; α – Cronbachov koeficijent alfa; M i SD – aritmetička sredina i standardna devijacija kompozitne mjere.

Opterećenja su značajna i kreću se od 0,634 do 0,942, Cronbachov alfa i CR veći su od 0,74, a AVE veći od 0,50 za sve dimenzije. Sve HTMT vrijednosti niže su od 0,90, a Fornell-Larckerov kriterij nije zadovoljen samo za intenziviranje uporabe (√AVE = 0,712), visoko korelirano s recikliranjem (0,88) i dematerijalizacijom (0,82), što je očekivano za dimenzije istog konstrukta drugog reda. Podobnost mjernog modela je ograničena ($\chi^2$/df = 3,49; RMSEA = 0,096; SRMR = 0,070; CFI = 0,860; TLI = 0,834): SRMR je prihvatljiv, dok CFI, TLI i RMSEA ne dosežu uobičajene pragove, što je uzeto u obzir pri tumačenju rezultata. Prvi neizrotirani faktor objašnjava 42,6 % varijance, a latentni metodski faktor u prosjeku 12,9 % varijance indikatora

(uz njega CFI = 0,913; RMSEA = 0,079). Pristranost zajedničke metode stoga je prisutna, ali ne dominira, pa su strukturni modeli procijenjeni i uz kontrolu metodskog faktora.

## 4.2. Utjecaj inovativnosti na implementaciju kružnih poslovnih modela

**Tablica 2. Rezultati testiranja hipoteza H1 – H1d**

| Veza | B | SE | β | p | β (metodski faktor) | β (n = 306) |
|---|---|---|---|---|---|---|
| ***Model A ($R^2$ = 0,851)*** | | | | | | |
| H1: Inovativnost → KPM | 0,920 | 0,102 | 0,928 | < 0,001 | 0,711*** | 0,880*** |
| ***Model B ($R^2$ = 0,754)*** | | | | | | |
| H1a: Inovacije proizvoda → KPM | 0,292 | 0,101 | 0,356 | 0,004 | 0,638** | 0,293* |
| H1b: Inovacije procesa → KPM | 0,157 | 0,154 | 0,121 | 0,306 | –0,402* | 0,075 |
| H1c: Organizacijske inovacije → KPM | 0,412 | 0,066 | 0,479 | < 0,001 | 0,541*** | 0,436*** |
| H1d: Marketinške inovacije → KPM | 0,181 | 0,066 | 0,182 | 0,006 | –0,014 | 0,303*** |

Izvor: izrada autorica. Napomena: B – nestandardizirani koeficijent; SE – standardna pogreška; β – standardizirani koeficijent; kontrolirani su veličina poduzeća i prerađivačka industrija. Podobnost: model A $\chi^2/df = 3,79$, RMSEA = 0,102, SRMR = 0,094, CFI = 0,822; model B $\chi^2/df = 3,58$, RMSEA = 0,098, SRMR = 0,086, CFI = 0,841. Stupci desno prikazuju provjere robusnosti: uz latentni metodski faktor (CFI = 0,885 i 0,891) i na cjelovitom uzorku. * p < 0,05; ** p < 0,01; *** p < 0,001.

U modelu A (tablica 2.) sve dimenzije značajno se vežu na konstrukte drugog reda (λ od 0,271 za marketinške inovacije do 0,944 za intenziviranje uporabe). Inovativnost snažno i značajno utječe na implementaciju KPM-a (β = 0,928; p < 0,001; $R^2$ = 0,851), pa je H1 potvrđena. Uz metodski faktor učinak ostaje značajan (β = 0,711), što znači da je jačina veze dijelom posljedica zajedničke metode, ali sama veza nije njezin artefakt; HTMT između dvaju konstrukata iznosi 0,85. Model B pokazuje da se učinak

razlikuje prema vrsti inovacija: inovacije proizvoda (β = 0,356; p = 0,004) i organizacijske inovacije (β = 0,479; p < 0,001) značajne su u svim provjerama robusnosti (H1a i H1c potvrđene), marketinške inovacije (β = 0,182; p = 0,006) nisu značajne uz metodski faktor (H1d djelomično potvrđena), a procesne inovacije nemaju značajan neto učinak (H1b nije potvrđena).

**Tablica 3. Utjecaj vrsta inovacija na tipove kružnih poslovnih modela (model C, standardizirani koeficijenti)**

| Prediktor | Recikliranje | Produljenje vijeka | Intenziviranje uporabe | Dematerijalizacija |
|---|---|---|---|---|
| Inovacije proizvoda | 0,008 | 0,682*** | –0,133 | 0,560*** |
| Inovacije procesa | 0,627*** | –0,431*** | 0,498** | –0,151 |
| Organizacijske inovacije | 0,295*** | 0,477*** | 0,576*** | 0,342*** |
| Marketinške inovacije | –0,010 | 0,109 | 0,106 | 0,249** |
| $R^2$ | 0,599 | 0,729 | 0,651 | 0,612 |

Izvor: izrada autorica. Napomena: n = 271; podobnost: $\chi^2/df = 3,37$, RMSEA = 0,094, SRMR = 0,065, CFI = 0,878. ** p < 0,01; *** p < 0,001.

Model C (tablica 3.) pokazuje da inovacije proizvoda pokreću produljenje vijeka trajanja (β = 0,682) i dematerijalizaciju (β = 0,560), a procesne inovacije recikliranje (β = 0,627) i intenziviranje uporabe (β = 0,498), uz negativan neto učinak na produljenje vijeka trajanja (β = –0,431), što objašnjava izostanak njihova ukupnog učinka. Organizacijske inovacije jedine djeluju na sva četiri tipa (β od 0,295 do 0,576), a marketinške samo na dematerijalizaciju (β = 0,249).

## 4.3. Moderirajuća uloga vladine potpore i analiza prema vrstama inovacija

**Tablica 4. Moderirajući učinak vladine potpore (VP) na odnos inovativnosti i implementacije KPM-a**

| Interakcija | b | SE | p | 95 % CI (bootstrap) | $\Delta R^2$ |
|---|---|---|---|---|---|
| H2: Inovativnost × VP | 0,084 | 0,066 | 0,202 | [–0,021; 0,205] | 0,004 |
| Inovacije proizvoda × VP | 0,100 | 0,029 | < 0,001 | [0,040; 0,149] | 0,017 |
| Inovacije procesa × VP | 0,028 | 0,078 | 0,725 | [–0,080; 0,185] | 0,001 |
| Organizacijske inovacije × VP | 0,046 | 0,049 | 0,350 | [–0,040; 0,135] | 0,002 |
| Marketinške inovacije × VP | –0,049 | 0,042 | 0,247 | [–0,130; 0,025] | 0,003 |

Izvor: izrada autorica. Napomena: n = 271; zasebni modeli za svaku interakciju s centriranim prediktorima i kontrolnim varijablama; standardne pogreške HC3; bootstrap s 5.000 uzoraka. Za ukupnu inovativnost: b(inovativnost) = 0,591, b(VP) = 0,352 (oba $p < 0,001$), $R^2 = 0,706$; uvjetni učinak inovativnosti pri –1 SD i +1 SD VP iznosi 0,502 i 0,679.

Inovativnost (b = 0,591) i vladina potpora (b = 0,352) imaju značajne izravne učinke na implementaciju KPM-a ($R^2 = 0,706$), no interakcijski član nije značajan (b = 0,084; p = 0,202; 95 % CI [–0,021; 0,205]), a na cjelovitom uzorku značajan je samo na razini od 10 % (p = 0,071). Hipoteza H2 stoga nije potvrđena za ukupnu inovativnost, iako je predznak u skladu s očekivanjem (uvjetni učinak raste s 0,502 na 0,679). Za inovacije proizvoda moderacija je pozitivna i značajna (b = 0,100; $p < 0,001$; 95 % CI [0,040; 0,149]), što potvrđuje i cjeloviti uzorak ($p < 0,001$): njihov učinak iznosi 0,214 pri niskoj i 0,426 pri visokoj razini vladine potpore (±1 SD), odnosno gotovo je dvostruko veći. Za ostale vrste inovacija moderacija nije značajna (tablica 4.), pa je H2 djelomično potvrđena.

# 5. RASPRAVA

Rezultati potvrđuju da je inovativnost snažan pokretač kružne transformacije, u skladu s nalazima Kuzme i Sehnema (2023) te Brogija i Menichinija (2024), ali pokazuju i da ona nije homogen mehanizam. Organizacijske inovacije

jedine djeluju na sve tipove KPM-a, što potvrđuje da rutine i kultura učenja stvaraju uvjete u kojima druge inovacije daju kružne rezultate (Camisón i Villar-López, 2014). Inovacije proizvoda djeluju na modele koji ovise o dizajnu ponude, što odgovara razlikovanju inovacija u fazi uporabe i na ulazu životnog ciklusa (Chioatto i sur., 2020).

Procesne inovacije imaju dvojaku ulogu: pokreću recikliranje i intenziviranje uporabe, ali su uz kontrolu ostalih inovacija negativno povezane s produljenjem vijeka trajanja. Moguće objašnjenje jest njihova usmjerenost na učinkovitost i volumen proizvodnje, dakle na „lako ostvarive prilike“ (Bocken, Kimpimäki, Ritala i Konietzko, 2025), što odgovara pretežno tehnološkoj usmjerenosti inovacija u Hrvatskoj (Andabaka, Basarac Sertić i Harc, 2019). Marketing se, pak, tek iznimno koristi za komuniciranje kružne vrijednosne ponude.

Vladina potpora ima snažan izravan učinak, ali ne pojačava sustavno sve vrste inovacija. Najviše koristi imaju poduzeća koja inoviraju proizvode, vjerojatno zato što financiranje, partnerstva i edukacija smanjuju rizik redizajna ponude. To je u skladu s nalazima Rehmana i suradnika (2022), ali i s ocjenama o nedovoljno koordiniranim provedbenim mehanizmima u Hrvatskoj (Andabaka i sur., 2018). Nalazi se razlikuju od istraživanja u Bosni i Hercegovini (Umihanić i Tipurić, 2026), što potvrđuje da odnos inovativnosti i kružnosti ovisi o institucionalnom kontekstu.

## 6. ZAKLJUČNA RAZMATRANJA

Rad pokazuje da inovativnost značajno pridonosi implementaciji kružnih poslovnih modela u hrvatskim industrijskim poduzećima, ponajprije kroz organizacijske inovacije i inovacije proizvoda. Teorijski doprinos očituje se u pokazivanju da pojedine vrste inovacija pokreću različite putanje kružnosti te da vladina potpora ne djeluje kao opći pojačivač inovativnosti, nego kao komplement redizajnu proizvoda, čime se resursno utemeljeno objašnjenje dopunjuje institucionalnom perspektivom. Empirijski doprinos očituje se u primjeni integriranog modela u posttranzicijskom gospodarstvu, uz provjere robusnosti.

Menadžerima rezultati sugeriraju da kružnu transformaciju grade na organizacijskim inovacijama i redizajnu proizvoda prema trajnosti i digitalnim rješenjima te da procesne inovacije svjesno povežu s dugotrajnošću proizvoda. Kreatorima javnih politika poručuju da instrumenti

potpore trebaju biti dugoročni i usklađeni (Tipurić, Vlačić, Radak i Vučković, 2024) te ciljano usmjereni na razvoj i redizajn proizvoda.

Ograničenja proizlaze iz presječnog dizajna, perceptivnih mjera jednog ispitanika po poduzeću i potvrđene pristranosti zajedničke metode, granične podobnosti modela, skraćenih ljestvica, moderacije ispitane na kompozitnim mjerama te usmjerenosti na jednu zemlju i sekundarni sektor. Buduća istraživanja trebala bi primijeniti longitudinalni dizajn, objektivne pokazatelje kružnosti i latentne modele moderacije u drugim institucionalnim kontekstima.

# LITERATURA

Andabaka, A., Basarac Sertić, M. i Harc, M. (2019). Eco-innovation and economic growth in the European Union. Zagreb International Review of Economics & Business, 22(2), 43-54. https://doi.org/10.2478/zireb-2019-0019

Andabaka, A., Beg, M. i Gelo, T. (2018). Challenges of circular economy in Croatia. International Journal of Multidisciplinarity in Business and Science, 4(5), 115-126.

Barney, J. (1991). Firm resources and sustained competitive advantage. Journal of Management, 17(1), 99-120. https://doi.org/10.1177/014920639101700108

Bocken, N. M. P., de Pauw, I., Bakker, C. i van der Grinten, B. (2016). Product design and business model strategies for a circular economy. Journal of Industrial and Production Engineering, 33(5), 308-320. https://doi.org/10.1080/21681015.2016.1172124

Bocken, N., Kimpimäki, J., Ritala, P. i Konietzko, J. (2025). How circular are large corporations? Evidence from a large-scale survey with senior leaders. Resources, Conservation and Recycling, 215, 108151. https://doi.org/10.1016/j.resconrec.2025.108151

Brogi, S. i Menichini, T. (2024). The pathway towards circular economy: Measuring circular advantage of eco-innovations. Business Strategy and the Environment, 33(4), 3005-3038. https://doi.org/10.1002/bse.3621

Camisón, C. i Villar-López, A. (2014). Organizational innovation as an enabler of technological innovation capabilities and firm performance. Journal of Business Research, 67(1), 2891-2902. https://doi.org/10.1016/j.jbusres.2012.06.004

Centobelli, P., Cerchione, R., Chiaroni, D., Del Vecchio, P. i Urbinati, A. (2020). Designing business models in circular economy: A systematic literature review and research agenda. Business Strategy and the Environment, 29(4), 1734-1749. https://doi.org/10.1002/bse.2466

Chioatto, E., Zecca, E. i D'Amato, A. (2020). Which innovations for a circular business model? A product life-cycle approach (FEEM Working Paper No. 029.2020). Milano: Fondazione Eni Enrico Mattei.

Dangelico, R. M. i Pujari, D. (2010). Mainstreaming green product innovation: Why and how companies integrate environmental sustainability. Journal of Business Ethics, 95, 471-486. https://doi.org/10.1007/s10551-010-0434-0

De Jesus, A. i Mendonça, S. (2018). Lost in transition? Drivers and barriers in the eco-innovation road to the circular economy. Ecological Economics, 145, 75-89. https://doi.org/10.1016/j.ecolecon.2017.08.001

Eurostat. (2025). Circular material use rate. Luxembourg: Eurostat. Dostupno na https://ec.europa.eu/eurostat/databrowser/view/env_ac_cur/default/table?lang=en

Fornell, C. i Larcker, D. F. (1981). Evaluating structural equation models with unobservable variables and measurement error. Journal of Marketing Research, 18(1), 39-50. https://doi.org/10.1177/002224378101800104

García-Quevedo, J., Jové-Llopis, E. i Martínez-Ros, E. (2020). Barriers to the circular economy in European small and medium-sized firms. Business Strategy and the Environment, 29(6), 2450-2464. https://doi.org/10.1002/bse.2513

Geissdoerfer, M., Pieroni, M. P. P., Pigosso, D. C. A. i Soufani, K. (2020). Circular business models: A review. Journal of Cleaner Production, 277, 123741. https://doi.org/10.1016/j.jclepro.2020.123741

Geissdoerfer, M., Vladimirova, D. i Evans, S. (2018). Sustainable business model innovation: A review. Journal of Cleaner Production, 198, 401-416. https://doi.org/10.1016/j.jclepro.2018.06.240

Hayes, A. F. (2018). Introduction to mediation, moderation, and conditional process analysis: A regression-based approach (2. izd.). New York: Guilford Press.

Henseler, J., Ringle, C. M. i Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. Journal of the Academy of Marketing Science, 43(1), 115-135. https://doi.org/10.1007/s11747-014-0403-8

Horbach, J., Rammer, C. i Rennings, K. (2012). Determinants of eco-innovations by type of environmental impact – The role of regulatory push/pull, technology push and market pull. Ecological Economics, 78, 112-122. https://doi.org/10.1016/j.ecolecon.2012.04.005

Khan, O., Daddi, T. i Iraldo, F. (2020). The role of dynamic capabilities in circular economy implementation and performance of companies. Corporate Social Responsibility and Environmental Management, 27(6), 3018-3033. https://doi.org/10.1002/csr.2020

Kirchherr, J., Piscicelli, L., Bour, R., Kostense-Smit, E., Muller, J., Huibrechtse-Truijens, A. i Hekkert, M. (2018). Barriers to the circular economy: Evidence from the European Union (EU). Ecological Economics, 150, 264-272. https://doi.org/10.1016/j.ecolecon.2018.04.028

Kristoffersen, E., Mikalef, P., Blomsma, F. i Li, J. (2021). The effects of business analytics capability on circular economy implementation, resource orchestration capability, and firm performance. International Journal of Production Economics, 239, 108205. https://doi.org/10.1016/j.ijpe.2021.108205

Kuzma, E. i Sehnem, S. (2022). Validation of the measurement scale for the circular economy: A proposal based on the precepts of innovation. International Journal of Professional Business Review, 7(1), e0278. https://doi.org/10.26668/businessreview/2022.v7i1.278

Kuzma, E. i Sehnem, S. (2023). Proposition of a structural model for business value creation based on circular business models, innovation, and resource recovery in the pet industry. Business Strategy and the Environment, 32(1), 516-537. https://doi.org/10.1002/bse.3158

Lovrenčić Butković, L. i Mihaljević, M. (2021). Poznavanje koncepta kružne ekonomije u građevinskom sektoru. Ekonomska misao i praksa, 30(2), 587-608. https://doi.org/10.17818/EMIP/2021/2.14

Ministarstvo gospodarstva Republike Hrvatske. (2025). Nacionalni plan razvoja kružnog gospodarstva Republike Hrvatske za razdoblje od 2026. do 2032. Dostupno na https://mingo.gov.hr

OECD. (2018). Oslo Manual 2018: Guidelines for collecting, reporting and using data on innovation (4. izd.). Paris: OECD Publishing. https://doi.org/10.1787/9789264304604-en

Podsakoff, P. M., MacKenzie, S. B., Lee, J.-Y. i Podsakoff, N. P. (2003). Common method biases in behavioral research: A critical review of the literature and recommended remedies. Journal of Applied Psychology, 88(5), 879-903. https://doi.org/10.1037/0021-9010.88.5.879

Rehman, F. U., Al-Ghazali, B. M. i Farook, M. R. M. (2022). Interplay in circular economy innovation, business model innovation, SDGs, and government incentives: A comparative analysis of Pakistani, Malaysian, and Chinese SMEs. Sustainability, 14(23), 15586. https://doi.org/10.3390/su142315586

Rizos, V., Behrens, A., van der Gaast, W., Hofman, E., Ioannou, A., Kafyeke, T., Flamos, A., Rinaldi, R., Papadelis, S., Hirschnitz-Garbers, M. i Topi, C. (2016). Implementation of circular economy business models by small and medium-sized enterprises (SMEs): Barriers and enablers. Sustainability, 8(11), 1212. https://doi.org/10.3390/su8111212

Sehnem, S., de Queiroz, A. A. F. S. L., Pereira, S. C. F., dos Santos Correia, G. i Kuzma, E. (2022). Circular economy and innovation: A look from the perspective of organizational capabilities. Business Strategy and the Environment, 31(1), 236-250. https://doi.org/10.1002/bse.2884

Teece, D. J. (2007). Explicating dynamic capabilities: The nature and microfoundations of (sustainable) enterprise performance. Strategic Management Journal, 28(13), 1319-1350. https://doi.org/10.1002/smj.640

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

Tipurić, D., Vlačić, E., Radak, I. i Vučković, A. (2024). Implementing ESG principles in pharma industry in emerging markets. Ekonomika preduzeća, 72(7-8), 347-360. https://doi.org/10.5937/EKOPRE2408347T

Umihanić, U. (2026). Implementacija kružnoga poslovnoga modela u procesu unaprjeđenja performansi uspješnosti poduzeća (doktorski rad). Zagreb: Ekonomski fakultet Sveučilišta u Zagrebu.

Umihanić, U. i Tipurić, D. (2026). The determining role of firm innovativeness in the implementation of circular business models: An empirical study of the manufacturing industry in Bosnia and Herzegovina. Management: Journal of Contemporary Management Issues, 31(1), 30-51. https://doi.org/10.30924/mjcmi.31.1.2

# IMPLEMENTATION OF CIRCULAR BUSINESS MODELS IN CROATIAN INDUSTRIAL FIRMS: THE ROLE OF INNOVATIVENESS AND GOVERNMENT SUPPORT

***Abstract***

*The transition to a circular economy requires firms to develop and implement business models that simultaneously contribute to sustainability, innovativeness and long-term competitiveness. The aim of this paper is to examine the relationship between firm innovativeness and its dimensions and the implementation of circular business models in Croatian industrial firms and to determine whether government support moderates this relationship. The empirical research was conducted by means of a questionnaire on a sample of 306 firms from NACE sections B–F with at least ten employees, of which 271 were retained in the analysis. Measurement models were verified by confirmatory factor analysis, the conceptual model was tested by covariance-based structural equation modelling (CB-SEM), and the moderating effect by moderated regression analysis with bootstrapping. The results confirm that firm innovativeness has a strong, positive and statistically significant effect on circular business model implementation, with product and organisational innovations emerging as the most stable drivers. Government support does not significantly moderate the relationship between overall innovativeness and circular business model implementation, but it strengthens the effect of product innovation, which is almost twice as pronounced in firms with higher levels of government support. The results highlight the importance of simultaneously developing organisational capabilities and targeted institutional support and have implications for managers and policy-makers. Limitations stem from the cross-sectional design, single-respondent perceptual measures and the focus on Croatian industrial firms. The scientific contribution lies in the empirical examination of the relationships between types of innovation, government support and types of circular business models in the Croatian context, thereby extending knowledge of the organisational and institutional determinants of the circular transition.*

***Keywords:*** *circular economy, circular business models, firm innovativeness, government support, structural equation modelling.*

JEL klasifikacija: O33, M15, L25

Stručni rad

# DIGITALNA TRANSFORMACIJA I DIGITALNA ZRELOST: KONCEPTUALNE RAZLIKE I NJIHOV MEĐUSOBNI ODNOS

Sanel Volarić*

## SAŽETAK

**Svrha**. Digitalna transformacija i digitalna zrelost postali su istaknuti koncepti u istraživačkoj i menadžerskoj praksi, no njihove konceptualne granice i međusobni odnos ostaju nedovoljno jasni, što je jedan od mogućih razloga loše učinkovitosti kontinuirano rastućih digitalnih ulaganja (Yahnyuk, 2025, Hamane, 2026). Cilj ovog rada jest razlikovati dva konstrukta i razviti teoretski utemeljeno objašnjenje njihova odnosa.

**Metodologija**. Rad usvaja strukturirani integrativni konceptualni pregled i teorijsku sintezu. Integrira četiri komplementarna toka literature: digitalnu transformaciju, digitalnu zrelost, dinamičke sposobnosti i privremenu konkurentsku prednost. Ključni doprinosi kombiniraju se s nedavnim radovima koji eksplicitno povezuju organizacijske sposobnosti, procese transformacije i digitalnu zrelost. Literatura se analizira kroz perspektivu procesa i stanja i sintetizira korištenjem teorije dinamičkih sposobnosti kao glavne teorijske leće.

**Nalazi**. Analiza pokazuje da digitalnu transformaciju i digitalnu zrelost treba tretirati kao povezane, ali različite organizacijske fenomene. Digitalna

* Mr. sc. Sanel Volarić, MBA, Sveučilište u Splitu, Ekonomski fakultet (e-mail: sanel.volaric@gmail.com).

transformacija konceptualizira se kao kontinuirani proces digitalno omogućenih organizacijskih promjena kroz koje poduzeća rekonfiguriraju strategije, resurse, strukture, procese, rutine i poslovne modele. Digitalna zrelost predstavlja akumulirano višedimenzionalno stanje organizacijskih digitalnih sposobnosti koje proizlaze iz uspješnih transformacijskih napora. Odnos nije potpuno linearan: transformacija doprinosi akumulaciji sposobnosti i većoj zrelosti, dok akumulirana zrelost potom jača kapacitet poduzeća za daljnju transformaciju. Ovaj rekurzivni mehanizam pomaže objasniti zašto se ulaganja u tehnologiju i transformacijske aktivnosti ne prevode automatski u organizacijsku uspješnost.

**Originalnost i doprinos**. Rad doprinosi konceptualnoj jasnoći razvojem eksplicitne razlike između procesa i stanja digitalne transformacije i digitalne zrelosti te njezinom integracijom s dinamičkim sposobnostima i privremenom konkurentskom prednošću. Nadalje, predlaže rekurzivni model razvoja sposobnosti koji povezuje transformaciju, organizacijsko učenje, akumulaciju sposobnosti, zrelost i naknadnu transformaciju.

**Ograničenja**. Kao konceptualna studija temeljena na integrativnom, a ne sustavnom pregledu literature, predloženi odnosi nisu empirijski testirani. Buduća istraživanja trebala bi operacionalizirati konstrukte zasebno, longitudinalno testirati predloženi odnos između procesa i stanja te ispitati varira li mehanizam ovisno o industrijama, veličinama poduzeća i razinama dinamike okoline.

**Ključne riječi**: digitalna transformacija, digitalna zrelost, dinamičke sposobnosti, privremena konkurentska prednost, organizacijske sposobnosti, digitalne tehnologije.

# 1. UVOD

Širenje digitalnih tehnologija predstavlja jednu od najznačajnijih sila koje preoblikuju suvremena gospodarstva. Umjetna inteligencija, napredna analitika, računarstvo u oblaku, digitalne platforme, mobilne tehnologije i Internet stvari utječu ne samo na način na koji poduzeća obavljaju pojedinačne aktivnosti, već i na način na koji stvaraju i integriraju vrijednost, komuniciraju s kupcima i partnerima, organiziraju resurse i natječu se. Kako se digitalne tehnologije ugrađuju u proizvode, procese i poslovne modele, tradicionalna razlika između informacijske tehnologije i poslovne strategije sve više gubi na važnosti (Bharadwaj i sur., 2013; Vial, 2019; Verhoef i sur., 2021).

Strateške posljedice protežu se dalje od tehnološke modernizacije. Digitalne tehnologije omogućuju brzo eksperimentiranje, povećavaju brzinu i dostupnost informacija, omogućuju nove oblike koordinacije i olakšavaju rekombiniranje resursa u nove proizvode, usluge i poslovne modele. Istodobno omogućuju novim konkurentima da izazovu postojeća poduzeća, ali i da probiju barijere industrija. Posljedično, digitalizacija utječe i na izvore konkurentske prednosti i na brzinu kojom se prednosti mogu stvarati, imitirati, zamjenjivati i obnavljati (Bharadwaj i sur., 2013; D'Aveni i sur., 2010).

Ovi su događaji uzdigli digitalnu transformaciju od pretežno tehnološkog problema do prioriteta strateškog upravljanja. Međutim, sama tehnološka ulaganja ne predstavljaju transformaciju, niti implementacija naprednih tehnologija nužno stvara odgovarajuće organizacijske sposobnosti ili ekonomsku vrijednost. Suvremena istraživanja stoga sve više konceptualiziraju digitalnu transformaciju kao širu organizacijsku i stratešku promjenu koja uključuje resurse, strukture, procese, rutine, kompetencije i mehanizme stvaranja vrijednosti (Vial, 2019; Warner & Wäger, 2019; Verhoef i sur., 2021).

Važno konceptualno pitanje pojavljuje se kada se digitalna transformacija razmatra zajedno s digitalnom zrelošću. Oba se koncepta široko koriste u akademskim i menadžerskim raspravama, ali njihove teorijske granice nisu uvijek jasne. Teichert (2019), na primjer, koristi kombinirani koncept zrelosti digitalne transformacije i analizira modele zrelosti koji se koriste za procjenu organizacija u kontekstu transformacije. Aras i Büyüközkan (2023) eksplicitno pozicioniraju procjenu digitalne zrelosti unutar puta digitalne transformacije i tvrde da se rezultati procjene mogu tumačiti paralelno s fazama tog puta. Nasiri i sur. (2022) operacionaliziraju digitalnu zrelost kroz razine koje su djelomično karakterizirane stupnjem u kojem su inicijative digitalne transformacije provedene. Najizravnije, Hamberg (2022) istražuje konceptualizaciju i odnos digitalne transformacije i digitalne zrelosti te izvještava o značajnoj dvosmislenosti koja okružuje oba konstrukta.

Ovi primjeri ne pokazuju da literatura univerzalno tretira digitalnu transformaciju i digitalnu zrelost kao identične. Umjesto toga, oni pokazuju da su dva konstrukta karakterizirana konceptualnom bliskošću, preklapajućim operacionalizacijama i nedosljednim graničnim uvjetima. Digitalna zrelost može se interpretirati kao napredak u transformaciji, kao spremnost za transformaciju, kao ishod transformacije ili kao prethodnik koji omogućuje daljnju transformaciju. Takva konceptualna višestrukost otežava utvrđivanje što se točno mijenja tijekom digitalne transformacije i što

predstavlja organizacijsko stanje koje proizlazi iz te promjene (Teichert, 2019; Hamberg, 2022; Aras i Büyüközkan, 2023).

Ova dvosmislenost je važna teoretski i upravljački. Ako se transformacijska aktivnost i zrelost tretiraju kao manifestacije istog fenomena, postaje teško objasniti zašto poduzeća koja provode opsežne programe transformacije dosežu različite razine organizacijskih sposobnosti i postižu različite ishode. Slično tome, ako se digitalna zrelost istodobno konceptualizira kao prethodnik, mjera, faza i ishod transformacije, kauzalno zaključivanje postaje problematično.

Središnji argument razvijen u ovom radu jest da su digitalna transformacija i digitalna zrelost usko povezane, ali konceptualno različite. Digitalna transformacija predstavlja kontinuirani proces digitalno omogućenih organizacijskih promjena kroz koje poduzeća rekonfiguriraju strategije, resurse, strukture, procese i poslovne modele. Digitalna zrelost predstavlja akumulirano višedimenzionalno stanje organizacijskih digitalnih sposobnosti koje proizlaze iz uspješnih transformacijskih napora.

Digitalna transformacija opisuje kako se organizacija mijenja primjenom digitalnih tehnologija, dok digitalna zrelost odražava organizacijske sposobnosti akumulirane kroz tu promjenu (Vial, 2019; Warner & Wäger, 2019; Leso i sur., 2024). Ova razlika pomaže objasniti zašto tehnološka ulaganja ne generiraju automatski poslovne rezultate: tehnologija stvara vrijednost samo kada poduzeća razviju sposobnosti da je integriraju, uče iz nje i u skladu s tim rekonfiguriraju resurse i rutine. Teorija dinamičkih sposobnosti pruža teorijsku osnovu za objašnjenje ovog mehanizma izgradnje sposobnosti (Eisenhardt & Martin, 2000; Teece, 2007).

Privremena priroda konkurentske prednosti dodatno jača ovaj argument. Ako se vrijednost određenih konkurentskih prednosti sve više smanjuje kako se tehnologije, očekivanja kupaca i konkurentski uvjeti mijenjaju, poduzeća se ne mogu oslanjati isključivo na određenu tehnologiju, proizvod ili poslovni model. Potrebna im je sposobnost kontinuiranog obnavljanja. U tim uvjetima, strateški značaj digitalne zrelosti ne leži u postizanju trajnog krajnjeg stanja, već u razvoju organizacijskog kapaciteta za ponovljenu transformaciju (D'Aveni i sur., 2010; Dagnino i sur., 2021).

Sukladno tome, svrha ovog rada jest trostruka. Prvo, pojašnjava konceptualne granice između digitalne transformacije i digitalne zrelosti. Drugo, razvija teorijsko objašnjenje njihova odnosa koristeći dinamičke sposobnosti kao

glavni teorijski mehanizam. Treće, predlaže rekurzivni konceptualni model u kojem digitalna transformacija razvija sposobnosti koje se akumuliraju u digitalnu zrelost, dok veća digitalna zrelost jača organizacijski kapacitet za naknadnu transformaciju.

# 2. METODOLOGIJA

## 2.1. Istraživački pristup

Ovaj rad usvaja konceptualni istraživački pristup temeljen na strukturiranom integrativnom pregledu literature i teorijskoj sintezi. Umjesto testiranja unaprijed definiranih odnosa s primarnim empirijskim podacima, rad integrira komplementarne tokove literature kako bi razjasnila konceptualne granice između digitalne transformacije i digitalne zrelosti te razvila teoretski utemeljeno objašnjenje njihova odnosa.

Ovaj metodološki izbor odražava prirodu istraživačkog problema. Središnje pitanje nije prije svega učestalost s kojom se pojavljuju određene definicije, već konceptualno značenje koje se pripisuje digitalnoj transformaciji i digitalnoj zrelosti, teorijski mehanizmi koji ih povezuju i implikacije alternativnih konceptualizacija.

Pregled je stoga strukturiran oko četiri međusobno povezana toka literature:

1. digitalna transformacija kao organizacijska i strateška promjena;

2. digitalna zrelost i modeli digitalne zrelosti;

3. dinamičke sposobnosti i razvoj organizacijskih sposobnosti; i

4. privremena konkurentska prednost i kontinuirana strateška obnova.

Prva dva toka pružaju konstrukte koji zahtijevaju pojašnjenje. Teorija dinamičkih sposobnosti pruža glavni mehanizam objašnjenja koji ih povezuje, dok privremena konkurentska prednost pruža širi strateški kontekst koji objašnjava zašto je kontinuirana obnova sposobnosti postala sve važnija.

## 2.2. Odabir literature i sinteza

Literatura za ovaj rad odabrana je prema konceptualnoj relevantnosti, a ne putem iscrpnoga sustavnog pregleda. Pojmovi za pretraživanje i njihove kombinacije odražavali su četiri teorijska područja, a prednost je dana trima

kategorijama doprinosa. Prvo, zadržani su temeljni teorijski radovi koji uspostavljaju temelje dinamičkih sposobnosti i privremene konkurentske prednosti. Drugo, korišteni su utjecajni konceptualni radovi i pregledi literature za uspostavljanje suvremenog razumijevanja digitalne transformacije i digitalne zrelosti. Treće, uključena su nedavna istraživanja koja eksplicitno ispituju presjek između transformacije, zrelosti i organizacijskih sposobnosti.

Ovaj pristup stvara namjernu vremensku kombinaciju. Eisenhardt i Martin (2000), Winter (2003) i Teece (2007) uspostavljaju temelj dinamičkih sposobnosti, dok Wiggins i Ruefli (2005), D'Aveni i sur. (2010) i Dagnino i sur. (2021) uspostavljaju perspektivu privremene prednosti. Vial (2019), Warner i Wäger (2019) te Verhoef i sur. (2021) pružaju središnje konceptualizacije digitalne transformacije. Teichert (2019), Nasiri i sur. (2022), Aras i Büyüközkan (2023) te Senna i sur. (2023) pružaju komplementarne perspektive o digitalnoj zrelosti. Konačno, Konopik i sur. (2022), Leso i sur. (2024) i Jie i sur. (2025) pružaju izravnije suvremene dokaze o odnosu između transformacije, zrelosti i organizacijskih sposobnosti.

Sinteza je slijedila tri analitička koraka. Prvo, digitalna transformacija i digitalna zrelost ispitane su neovisno kako bi se identificirale njihove temeljne konceptualne karakteristike. Drugo, područja preklapanja i dvosmislenosti identificirana su analizom radova u kojima se pojavljuju oba konstrukta ili gdje je zrelost eksplicitno ugrađena u okvir transformacije. Treće, dva konstrukta integrirana su kroz teoriju dinamičkih sposobnosti i interpretirana kroz perspektivu procesa i stanja.

## 3. DIGITALNE TEHNOLOGIJE I RASTUĆA PRIVREMENOST KONKURENTSKIH PREDNOSTI

Strateška važnost digitalne transformacije ne može se u potpunosti razumjeti bez temeljitog razmatranja tektonskih promjena prirode razvoja i vijeka trajanja konkurentskih prednosti. Tradicionalna istraživanja strateškog menadžmenta posvetila su znatnu pozornost razumijevanju načina na koji poduzeća stvaraju i održavaju pobjedničke konkurentske pozicije. Međutim, rastuće tehnološke promjene, inovacije, globalizacija i tržišne turbulencije dovele su u pitanje, nekad prevladavajuće, pretpostavke da konkurentske prednosti mogu ostati stabilne dulje vrijeme. Još su Wiggins i Ruefli (2005) pružili empirijske dokaze koji su ukazali na skraćivanje razdoblja superiornih performansi, dok D'Aveni i sur. (2010) utvrdili kako se poduzeća sve više

natječu kroz nizove privremenih prednosti, a ne oslanjanjem na jedan održivi izvor superiornosti.

Naknadna literatura naglasila je važnost ove perspektive. Dagnino i sur. (2021), analizirajući literaturu o privremenom karakteru konkurentskih prednosti, pokazuju kako se fokus istraživanja u području strateškog upravljanja sve više pomiče prema razumijevanju prethodnika, upravljanja i posljedica privremenosti konkurentskih prednosti. Iako je održiva konkurentska prednost i dalje moguća, rastuća tržišna dinamika i tehnološke promjene zahtijevaju od poduzeća da se kontinuirano prilagođavaju i obnavljaju svoje izvore konkurentske prednosti (Wiggins i Ruefli, 2005; D'Aveni i sur., 2010; Dagnino i sur., 2021).

Digitalne tehnologije intenziviraju ovu dinamiku, povećavajući brzinu i načine komunikacije, olakšavaju brzo eksperimentiranje, omogućuju nove oblike ulaska na tržište i olakšavaju rekombinaciju resursa. Digitalne platforme i modularne arhitekture omogućuju poduzećima povezivanje dionika i sposobnosti preko tradicionalnih organizacijskih granica, dok analitika podataka i umjetna inteligencija mogu znatno ubrzati cikluse odlučivanja i inovacija. Ono što omogućuju poduzećima brzo stvaranje novih konkurentskih prednosti, također, može olakšati imitaciju, zamjenu ili tehnološko nadrastanje od strane konkurenata (Bharadwaj i sur., 2013; Vial, 2019).

Ključna strateška tema poduzeća stoga se radikalno mijenja, pomičući fokus s pitanja kako poduzeće može uspostaviti i braniti određenu konkurentsku prednost na razmatranje kako može opetovano identificirati, stvoriti, obnoviti i zamijeniti izvore prednosti kako se prilike u okolini mijenjaju (D'Aveni i sur., 2010; Dagnino i sur., 2021).

Ova promjena ima važne implikacije za digitalnu transformaciju. Ako se tehnologije i konkurentski uvjeti kontinuirano razvijaju, digitalna transformacija logički se ne može shvatiti kao jednokratni prijelaz iz analogne organizacije u trajno transformiranu digitalnu organizaciju. Ne postoji stabilno tehnološko krajnje stanje prema kojem sva poduzeća konvergiraju. Umjesto toga, poduzećima koja žele opstati u digitalnoj eri potreban je trajni kapacitet za transformaciju.

Ovo zapažanje također mijenja tumačenje digitalne zrelosti. Zrela organizacija ne može jednostavno biti ona koja je usvojila današnje napredne tehnologije. Takva definicija bi zrelost učinila vrlo ovisnom o tehnologiji i brzo zastarjelom. Strateški smislenija koncepcija odnosi se na akumulirani

kapacitet poduzeća da koristi digitalne tehnologije, organizacijsko znanje, podatke, strukture i rutine kako bi više puta reagiralo na promjene.

Perspektiva privremene prednosti stoga pruža širi strateški kontekst za odnos proces-stanje razvijen u ovom radu: transformacija je kontinuirana jer se konkurentski i tehnološki uvjeti kontinuirano mijenjaju, dok je pri tome zrelost presudna za uspjeh jer pruža bazu sposobnosti koja omogućava buduće kontinuirane prilagodbe.

## 4. DINAMIČKE SPOSOBNOSTI KAO TEORIJSKA PODLOGA

Teorija dinamičkih sposobnosti pruža teorijsko objašnjenje kako poduzeća prilagođavaju svoje konfiguracije resursa uvjetima promjena u okruženju. Eisenhardt i Martin (2000) konceptualiziraju dinamičke sposobnosti kao prepoznatljive organizacijske procese putem kojih poduzeća integriraju, rekonfiguriraju i oslobađaju resurse kao odgovor na ili u iščekivanju promjena na tržištu. Winter (2003) dodatno razlikuje dinamičke sposobnosti od običnih sposobnosti: obične sposobnosti omogućuju organizacijama obavljanje postojećih aktivnosti, dok se dinamičke sposobnosti odnose na modifikaciju tih aktivnosti i temeljne baze resursa.

Teece (2007) razvija perspektivu kroz tri široka skupa aktivnosti: prepoznavanje, iskorištavanje i rekonfiguracija. Prepoznavanje se odnosi na organizacijski kapacitet za prepoznavanje tehnološkog razvoja, promjena u ponašanju kupaca, konkurentskih prijetnji i prilika na tržištu u nastajanju. U digitalnoj eri, sposobnost prepoznavanja sve više ovisi o analitičkoj obradi podataka i interakciji ekosustava, tehnološkom skeniranju i mehanizmima koji omogućuju poduzećima da prepoznaju i interpretiraju signale prije nego što postanu u potpunosti uspostavljeni tržišni trendovi.

Sposobnost iskorištavanja odnosi se na mobilizaciju resursa oko identificiranih prilika. Može uključivati investicijske odluke, eksperimentiranje, razvoj proizvoda i usluga, odabir tehnologija, formiranje partnerstava i stvaranje ili redizajn poslovnih modela.

Rekonfiguracija se odnosi na sposobnost modificiranja organizacijskih resursa, procesa, struktura, rutina i kompetencija kada postojeće konfiguracije više nisu adekvatne. Upravo je ta sposobnost organizacijske rekombinacije posebno relevantna za digitalnu transformaciju (Teece, 2007).

Teorija dinamičkih sposobnosti stoga je usko povezana sa suvremenim tumačenjima digitalne transformacije. Digitalne tehnologije istodobno i stvaraju nove prilike, ali i destabiliziraju postojeće konfiguracije resursa i aktivnosti. Poduzećima je potrebno više od pristupa tehnologiji: potrebna im je organizacijska sposobnost da prepoznaju koje su tehnologije važne, odrede gdje i kako stvaraju vrijednost, mobiliziraju resurse oko njih i u skladu s tim redizajniraju organizacijske aranžmane (Warner & Wäger, 2019).

Warner i Wäger (2019) prikazuju ovu vezu eksplicitnom konceptualizirajući digitalnu transformaciju kao kontinuirani proces strateške obnove omogućen dinamičkim sposobnostima. Novija istraživanja pojačavaju ovu perspektivu razvoja sposobnosti. Konopik i sur. (2022), na temelju sveobuhvatne analize literature, identificiraju organizacijske sposobnosti potrebne tijekom cijelog procesa digitalne transformacije i organiziraju ih oko strategije i ekosustava, inovacija, tehnologija, podataka, operacija, organizacijskog dizajna i vodstva. Njihov okvir orijentiran na procese pokazuje da različite organizacijske sposobnosti postaju važne u različitim točkama transformacije i da se digitalna transformacija ne može svesti na tehnološko usvajanje.

Ova razlika pomaže objasniti zašto naizgled slična tehnološka ulaganja mogu proizvesti različite organizacijske rezultate. Infrastruktura u oblaku, softverske platforme, alati za analitiku i sve veće mogućnosti umjetne inteligencije dostupne su svim konkurentima. Ono što se značajnije razlikuje jest sposobnost kombiniranja tih resursa s organizacijskim znanjem, ljudskim kompetencijama, podacima, strukturama, procesima i strateškim prioritetima. Digitalne tehnologije stoga predstavljaju resurse i pokretače. Organizacijska sposobnost da se ti resursi opetovano iskorištavaju i rekonfiguriraju predstavlja sposobnost. Ova teorijska razlika pruža temelj za odvajanje digitalne transformacije od digitalne zrelosti.

# 5. DIGITALNA TRANSFORMACIJA I DIGITALNA ZRELOST: KONCEPTUALNE OSNOVE

## 5.1. Digitalna transformacija kao organizacijska promjena i proces izgradnje sposobnosti

Suvremene konceptualizacije digitalne transformacije obuhvaćaju puno širi organizacijski fenomen od pretvaranja analognih informacija u digitalni oblik ili primjenu digitalnih tehnologija na postojeće aktivnosti i procese (Vial,

2019; Verhoef i sur., 2021). Vial (2019) konceptualizira digitalnu transformaciju kao proces u kojem digitalne tehnologije generiraju disrupcije koje pokreću strateške odgovore i promjene u načinima stvaranja organizacijske vrijednosti, a istovremeno zahtijevaju od poduzeća da se pozabave strukturnim promjenama. Verhoef i sur. (2021) slično razlikuju digitalizaciju, digitalizaciju te digitalnu transformaciju i transformaciju pozicija kao najširu razinu organizacijske promjene.

Ova razlika je važna jer tehnološka implementacija nije ni nužan dokaz duboke organizacijske transformacije ni dovoljan dokaz razvoja sposobnosti. Zamjena papirnatih dokumenata elektroničkim ekvivalentima prije svega predstavlja digitizaciju. Automatizacija postojećeg procesa predstavlja digitalizaciju. Redizajniranje procesa, promjena organizacijskih odgovornosti, integriranje informacija u stvarnom vremenu u odluke i potencijalno mijenjanje ponude vrijednosti za kupce pomiče organizaciju prema transformaciji.

Strateški karakter digitalne transformacije dodatno potvrđuju Bharadwaj i suradnici (2013), koji tvrde da digitalne tehnologije sve više brišu uvriježenu razliku između poslovne i informacijsko-tehnološke strategije. Tehnologija više ne podržava samo unaprijed definiranu poslovnu strategiju; ona može temeljno utjecati na strateški opseg, opseg, brzinu i izvore stvaranja vrijednosti.

Warner i Wäger (2019) proširuju ovu logiku pozicionirajući digitalnu transformaciju kao kontinuiranu stratešku obnovu. Konopik i suradnici (2022) dodatno pokazuju da transformacija uključuje razvoj širokog portfelja organizacijskih sposobnosti, a ne fiksnog skupa tehnoloških sredstava.

Nadovezujući se na ove perspektive, ovaj rad definira digitalnu transformaciju kao kontinuirani proces digitalno omogućenih organizacijskih promjena kroz koje poduzeća rekonfiguriraju strategije, resurse, strukture, procese, rutine i poslovne modele kao odgovor na tehnološke i okolišne promjene.

Ova definicija ima tri važne implikacije. Prvo, digitalna transformacija je procesna. Odnosi se na organizacijske promjene koje se događaju tijekom vremena. Drugo, ona je organizacijska, a ne samo tehnološka. Implementacija tehnologije bez odgovarajućih promjena u procesima, strukturama, kompetencijama ili stvaranju vrijednosti predstavlja tehnološku modernizaciju, a ne sveobuhvatnu transformaciju.

Treće, uspješna transformacija stvara sposobnosti. Kroz eksperimentiranje, učenje, implementaciju, integraciju i rekonfiguraciju, transformacija može

ostaviti za sobom organizacijsko znanje, kompetencije, rutine, mehanizme upravljanja, resurse podataka i tehnološke arhitekture koje se mogu ponovno upotrijebiti tijekom naknadne prilagodbe (Warner & Wäger, 2019; Konopik i sur., 2022). Digitalna transformacija stoga se može tumačiti kao proces izgradnje i rekonfiguracije sposobnosti.

## 5.2. Digitalna zrelost kao multidimenzionalno stanje organizacijskih sposobnosti

Digitalna zrelost razvila se dijelom iz praktične potrebe za procjenom koliko su poduzeća učinkovito pozicionirana za korištenje digitalnih tehnologija i upravljanje transformacijom. Posljedično su se pojavili brojni modeli zrelosti, iako se znatno razlikuju u terminologiji, teorijskim temeljima, dimenzijama i pristupima mjerenju (Teichert, 2019; Aras i Büyüközkan, 2023).

Unatoč toj heterogenosti, vidljiv je važan obrazac: modeli digitalne zrelosti sve se više protežu izvan područja čiste tehnologije. Tipične dimenzije uključuju strategiju, upravljanje, organizacijsku kulturu, ljude i kompetencije, podatke i analitiku, tehnološku infrastrukturu, orijentaciju na kupce i operativne procese. Stoga se digitalna zrelost ne može adekvatno tumačiti samo kao tehnološka sofisticiranost (Teichert, 2019; Aras i Büyüközkan, 2023).

Senna i sur. (2023), sintetizirajući 55 modela zrelosti, potkrepljuju ovaj argument pokazujući važnost organizacijskih i okolišnih čimbenika uz tehnologiju. Njihovi empirijski dokazi ukazuju na to da poduzeća mogu ulagati u digitalne tehnologije, a pritom ne postizati organizacijska unaprjeđenja i prilagodbu okolini. Prisutnost napredne tehnologije stoga ne podrazumijeva nužno i jednaku razinu organizacijske zrelosti. Na primjer, poduzeće može koristiti sofisticiranu analitiku, dok upravljačke odluke ostaju uglavnom vođene intuicijom. Slično tome, organizacija može uvesti umjetnu inteligenciju, a nedostaju joj kompetencije, mehanizmi upravljanja i organizacijske rutine potrebne za njezinu učinkovitu integraciju. U svakom slučaju, tehnološka imovina postoji bez odgovarajuće integriranog stanja organizacijskih sposobnosti.

Westerman i sur. (2014) slično naglašavaju da uspješne digitalne organizacije kombiniraju tehnološke inicijative s vodstvom i organizacijskim sposobnostima. Digitalna zrelost stoga ne proizlazi samo iz akumulacije tehnologije već iz koordiniranog razvoja i integracije više organizacijskih

dimenzija. Sukladno tome, ovaj rad definira digitalnu zrelost kao akumulirano višedimenzionalno stanje organizacijskih digitalnih sposobnosti koje omogućuje poduzeću da sustavno iskorištava digitalne tehnologije za prilagodbu, inovacije, operativna poboljšanja i stvaranje vrijednosti.

Tri elementa ključna su za ovu definiciju. Digitalna zrelost predstavlja stanje jer opisuje konfiguraciju sposobnosti koja postoji u određenom trenutku. Akumulira se jer se sposobnosti progresivno razvijaju kroz iskustvo, eksperimentiranje, implementaciju, učenje i integraciju, a ne pojavljuju se automatski kada se tehnologija instalira.

Konačno, višedimenzionalna je jer digitalna zrelost zahtijeva usklađenost između tehnoloških resursa, strategije, podataka, procesa, ljudskih kompetencija, organizacijske kulture, upravljanja i orijentacije na kupca (Teichert, 2019; Aras & Büyüközkan, 2023; Senna i sur., 2023). Digitalna zrelost stoga se može shvatiti kao snimak akumulirane baze digitalnih sposobnosti poduzeća.

## 5.3. Konceptualna dvosmislenost i preklapanje u postojećoj literaturi

Gore predložena razlika nije dosljedno naglašavana u postojećim istraživanjima. Teichert (2019) koristi pojam zrelosti digitalne transformacije prilikom pregleda modela koji procjenjuju digitalnu zrelost i sposobnosti povezane s transformacijom. Aras i Büyüközkan (2023) konceptualiziraju modele digitalne zrelosti kao instrumente za vođenje puta digitalne transformacije i interpretiraju rezultate procjene zrelosti paralelno s fazama transformacije. Nasiri i sur. (2022) tretiraju digitalnu zrelost kao prethodnicu unutar postavki digitalne transformacije i operacionaliziraju razine zrelosti djelomično prema dubini i opsegu u kojem su inicijative digitalne transformacije provedene.

Hamberg (2022) pruža posebno izravne dokaze o konceptualnom problemu. Ispitujući posebno digitalnu transformaciju i digitalnu zrelost, rad opisuje konceptualnu dvosmislenost i predlaže da se digitalna transformacija potencijalno može tumačiti kao promjena između različitih stanja digitalne zrelosti.

Ovi radovi otkrivaju najmanje tri preklapajuća tumačenja. Prvo, digitalna zrelost može predstavljati trenutno stanje ili spremnost poduzeća prije ili

tijekom transformacije. Drugo, zrelost može predstavljati napredak na putu transformacije, što razine zrelosti čini učinkovito fazama transformacije. Treće, zrelost može predstavljati ishod ili akumulirano organizacijsko stanje koje proizlazi iz transformacije. Svako tumačenje može biti korisno za određene svrhe, ali njihovo istodobno korištenje bez pojašnjenja njihovih kauzalnih i vremenskih pozicija stvara konceptualnu dvosmislenost.

Literatura ne tretira nužno digitalnu transformaciju i digitalnu zrelost kao identične koncepte. Međutim, razlika između njih te priroda i smjer njihova odnosa ostaju nedovoljno jasni (Teichert, 2019; Hamberg, 2022; Aras i Büyüközkan, 2023). Digitalna zrelost različito se povezivala sa spremnošću za transformaciju, napretkom na putu transformacije i organizacijskim stanjem koje proizlazi iz digitalnog razvoja, ostavljajući njezin odnos s digitalnom transformacijom konceptualno dvosmislen.

## 5.4. Sustavno pojmovno razlikovanje

Digitalna transformacija je u osnovi orijentirana na procese: odnosi se na organizacijske promjene kroz vrijeme. Digitalna zrelost je u osnovi orijentirana na stanje: odnosi se na konfiguraciju organizacijskih digitalnih sposobnosti akumuliranih u određenom trenutku. Digitalna transformacija stoga odgovara na pitanje kako se organizacija mijenja. Digitalna zrelost odgovara na pitanje što je organizacija postala sposobna učiniti.

**Tablica 1. Konceptualna razlika između digitalne transformacije i digitalne zrelosti**

| Dimenzija | Digitalna transformacija | Digitalna zrelost |
|---|---|---|
| Temeljna priroda | Proces | Stanje |
| Glavna orijentacija | Organizacijska promjena i rekonfiguracija | Akumulirana organizacijska sposobnost |
| Vremenska perspektiva | Dinamičko i longitudinalno | Stanje u određenom trenutku |
| Primarno pitanje | Kako se organizacija mijenja? | Što je organizacija postala sposobna učiniti? |
| Uloga tehnologije | Pokretač, resurs i omogućitelj promjene | Ugrađena komponenta organizacijske sposobnosti |
| Glavni mehanizmi | Ulaganje, eksperimentiranje, učenje, integracija i | Akumulacija, ugrađivanje, usklađivanje i rutinizacija |

| Dimenzija | Digitalna transformacija | Digitalna zrelost |
|---|---|---|
| | rekonfiguracija | |
| Teorijski naglasak | Transformacija i strateška obnova | Konfiguracija sposobnosti |
| Očekivana posljedica | Stvaranje i rekonfiguracija organizacijskih sposobnosti | Povećana sposobnost prilagodbe i stvaranja vrijednosti |
| Konačno stanje | Nema trajnog završetka | Relativno stanje koje se može povećati ili pogoršati |

Ova razlika ima važnu implikaciju: intenzitet transformacije nije ekvivalentan digitalnoj zrelosti. Organizacija može poduzeti brojne transformacijske inicijative, ulagati velika sredstva u tehnologiju i istovremeno imati relativno nisku digitalnu zrelost ako novi resursi ostanu fragmentirani ili slabo ugrađeni u organizacijske modele. Suprotno tome, poduzeće sa značajnim akumuliranim digitalnim sposobnostima može privremeno poduzeti manje velikih transformacijskih inicijativa jer su mnoge sposobnosti već ugrađene u njezin normalan operativni model. Stoga relevantno pitanje nije koliko se transformacijskih aktivnosti događa, već proizvodi li transformacijska aktivnost integrirane organizacijske sposobnosti.

# 6. POVEZANOST IZMEĐU DIGITALNE TRANSFORMACIJE I DIGITALNE ZRELOSTI

## 6.1. Od transformacije do akumulacije sposobnosti

Nakon što se digitalna transformacija i digitalna zrelost konceptualno razdvoje, njihov odnos može se preciznije ispitati. Digitalne tehnologije i promjene u okolišu stvaraju i prilike i potrebu za organizacijsku prilagodbu. Poduzeća reagiraju kroz transformacijske inicijative koje uključuju tehnološka ulaganja, redizajn procesa, restrukturiranja, nove načine rada, eksperimentiranje s poslovnim modelima ili kombinacije ovih aktivnosti (Vial, 2019; Verhoef i sur., 2021).

Sama implementacija, međutim, ne stvara zrelost. Tijekom uspješne transformacije, poduzeća uče kako tehnologije međusobno djeluju s postojećim resursima i rutinama. Zaposlenici razvijaju kompetencije. Menadžeri stječu iskustvo s novim procesima odlučivanja. Arhitekture podataka i mehanizmi upravljanja se razvijaju. Međufunkcionalna

koordinacija može se poboljšati. Pojavljuju se nove organizacijske rutine koje se, kroz ponovljenu primjenu, ugrađuju.

Kroz ovaj mehanizam, transformacijska aktivnost pretvara se u organizacijske sposobnosti (Teece, 2007; Warner & Wäger, 2019; Konopik i sur., 2022). Leso i sur. (2024) pružaju posebno relevantne nedavne dokaze za ovo tumačenje. Kombinirajući teoriju dinamičkih sposobnosti s perspektivom digitalne zrelosti, oni istražuju sposobnosti koje leže u osnovi sposobnosti poduzeća da postane digitalno zrelo. Njihov okvir identificira procese i resurse putem kojih poduzeća razvijaju kapacitet za kontinuirane promjene, izravno povezujući razvoj sposobnosti s digitalnom zrelošću. Osnovni mehanizam predložen u ovom radu stoga se može predstaviti kao:

**Slika 1. Konceptualni model razvoja sposobnosti kontinuirane prilagodbe**

Digitalna zrelost stoga se ne kreira samim usvajanjem tehnologije. Ona nastaje kada transformacija stvori sposobnosti koje postaju integrirane i ugrađene u relevantne organizacijske dimenzije.

## 6.2. Od transformacijskih rezultata do organizacijskih sposobnosti

Ključni korak u objašnjavanju odnosa između digitalne transformacije i digitalne zrelosti jest razlikovanje neposrednih rezultata transformacijskih inicijativa od organizacijskih sposobnosti koje iz njih proizlaze. Digitalna transformacija može proizvesti vidljive rezultate poput novih tehnoloških infrastruktura, digitalnih platformi, automatiziranih procesa, arhitektura podataka ili redizajniranih organizacijskih aranžmana. Međutim, ti rezultati sami po sebi ne pokazuju da je organizacija razvila kapacitet za njihovo sustavno iskorištavanje. Iz perspektive dinamičkih sposobnosti, strateške posljedice ne proizlaze samo iz posjedovanja resursa već iz organizacijskih procesa kroz koje se resursi integriraju, rekombiniraju i rekonfiguriraju (Eisenhardt & Martin, 2000; Teece, 2007).

Pretvaranje rezultata transformacije u organizacijske sposobnosti zahtijeva eksperimentiranje, učenje, integraciju i rutinizaciju. Kroz ove mehanizme, tehnološki resursi se kombiniraju s organizacijskim znanjem, kompetencijama, procesima i aranžmanima upravljanja, dok novorazvijene prakse postaju ugrađene i ponovljive. Digitalna transformacija stoga se može shvatiti kao proces razvoja sposobnosti, a ne kao akumulacija tehnoloških resursa (Warner & Wäger, 2019; Konopik i sur., 2022).

Ova razlika također pomaže objasniti zašto usporediva tehnološka ulaganja mogu proizvesti različite organizacijske ishode. Naime, često se događa da poduzeća implementiraju slične tehnologije, ali uz značajno različitu razinu sposobnosti da ih integriraju u poslovni model. Strateški relevantan ishod transformacije stoga nije samo tehnološki artefakt već organizacijska sposobnost koja ostaje nakon njegove implementacije i može se više puta mobilizirati u sljedećim situacijama (Teece, 2007; Vial, 2019).

Nedavna istraživanja koja integriraju dinamičke sposobnosti i digitalnu zrelost pojačavaju ovo tumačenje. Leso i sur. (2024) identificiraju organizacijske sposobnosti koje leže u osnovi sposobnosti postizanja digitalne zrelosti i povezuju zrelost sa sposobnošću za kontinuirane organizacijske promjene.

Digitalna transformacija stoga ne proizvodi automatski digitalnu zrelost. Zrelost se pojavljuje u mjeri u kojoj se rezultati transformacije pretvaraju u ugrađene, integrirane i ponovljive organizacijske sposobnosti. Razlike u ovom procesu pretvorbe sposobnosti mogu posljedično pomoći u objašnjavanju zašto poduzeća koja poduzimaju naizgled slične transformacijske inicijative razvijaju različite razine digitalne zrelosti i različite kapacitete za naknadnu prilagodbu (Konopik i sur., 2022; Leso i sur., 2024).

## 6.3. Rekurzivni, a ne čisto linearni odnos

Odnos između digitalne transformacije i digitalne zrelosti ne treba tumačiti kao isključivo linearan. Dok uspješna transformacija razvija i integrira organizacijske sposobnosti i time doprinosi digitalnoj zrelosti, akumulirana zrelost može naknadno ojačati kapacitet poduzeća za daljnju transformaciju. Utvrđene tehnološke, podatkovne, organizacijske i sposobnosti učenja pružaju jači temelj za prepoznavanje tehnoloških i tržišnih promjena, iskorištavanje novih prilika i rekonfiguraciju organizacijskih resursa (Teece, 2007; Warner & Wäger, 2019; Aras & Büyüközkan, 2023).

Nedavna istraživanja podupiru ovo recipročno tumačenje. Leso i sur. (2024) povezuju digitalnu zrelost s organizacijskim kapacitetom za kontinuirane promjene, dok Jie i sur. (2025), na temelju dokaza iz visokotehnoloških malih i srednjih poduzeća, otkrivaju da digitalna zrelost pozitivno utječe na dinamičke sposobnosti i da te sposobnosti posreduju u njezinu odnosu s inovacijskim učinkom. Iako se ovaj uzročni smjer razlikuje od slijeda transformacije prema zrelosti razvijenog u ovom radu, on ga nadopunjuje, a ne proturječi mu: sposobnosti razvijene transformacijom akumuliraju se u digitalnu zrelost, dok ova akumulirana baza sposobnosti jača naknadno prepoznavanje, iskorištavanje i rekonfiguraciju resursa u cilju prilagodbe (Teece, 2007; Leso i sur., 2024; Jie i sur., 2025).

Odnos je stoga rekurzivan: digitalna transformacija doprinosi digitalnoj zrelosti, dok digitalna zrelost jača kapacitet za naknadnu digitalnu transformaciju. Poduzeća posljedično napreduju kroz ponovljene cikluse transformacije, učenja, akumulacije sposobnosti i obnove, a ne prema trajno transformiranom krajnjem stanju (Warner & Wäger, 2019; Leso i sur., 2024).

## 6.4. Erozija sposobnosti i relativna priroda zrelosti

Perspektiva privremenosti, odnosno sve kraćeg vijeka trajanja, konkurentskih prednosti uvodi još jedan važan element. Digitalna zrelost ne može se tretirati kao trajno akumulirani napredak. Sposobnosti koje su vrijedne u jednom tehnološkom režimu mogu postati manje vrijedne ili bezvrijedne kako se tehnologije i tržišta razvijaju. Naslijeđene arhitekture mogu ograničiti prilagodbu. Prethodno uspješne rutine mogu postati organizacijske krutosti. Vještine mogu zastarjeti, a podaci ili upravljački aranžmani osmišljeni za jednu generaciju tehnologija mogu postati neadekvatni za drugu (Eisenhardt & Martin, 2000; D'Aveni i sur., 2010; Dagnino i sur., 2021).

Digitalna zrelost je stoga i akumulirana i relativna. Poduzeće koje je prije nekoliko godina posjedovalo visoku digitalnu zrelost ne smije pretpostaviti da će ostati jednako zrelo pod bitno drugačijim tehnološkim i konkurentskim uvjetima, jer strateška vrijednost sposobnosti ovisi o njihovoj kontinuiranoj usklađenosti s promjenjivim zahtjevima okoline (D'Aveni i sur., 2010; Dagnino i sur., 2021). Održavanje zrelosti posljedično zahtijeva kontinuirano učenje, obnavljanje sposobnosti i daljnju transformaciju (Warner i Wäger, 2019; Leso i sur., 2024).

To pojačava rekurzivni karakter predloženog odnosa: transformacija razvija

zrelost, ali održavanje same zrelosti zahtijeva kontinuiranu transformaciju (Warner i Wäger, 2019; Leso i sur., 2024).

## 6.5. Problem konverzije ulaganja u sposobnosti

Razlika između procesa i stanja također pruža teorijsko objašnjenje zašto značajna digitalna ulaganja mogu proizvesti heterogene organizacijske ishode. Poduzeća često upravljaju transformacijom putem portfelja projekata i procjenjuju uspjeh putem pokazatelja kao što su rokovi isporuke, usklađenost s proračunom, funkcionalnost sustava ili broj digitaliziranih procesa. Međutim, takve mjere ocjenjuju samo kvalitetu implementacije i isporuka, ali ne i učinkovitost stvaranja novih organizacijskih sposobnosti. Ovaj mehanizam konverzije ulaganja u transformacije je, u biti, niz konverzija kod kojeg se neuspjeh može dogoditi u bilo kojoj od pojedinačnih konverzija:

**Slika 2. Mehanizam konverzija ulaganja u transformacije do konkretnih poslovnih rezultata**

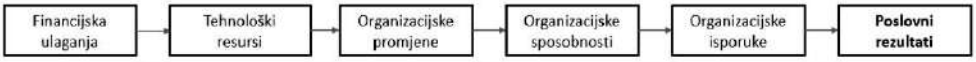


Prema tome, put od digitalnih ulaganja do poslovnih rezultata je dug i neizvjestan. Organizacijska vrijednost ovisi o tome pretvaraju li se transformacijska ulaganja u sposobnosti i jesu li te sposobnosti potom raspoređene na načine koji stvaraju operativne, strateške ili inovacijske rezultate (Teece, 2007; Vial, 2019). Digitalna zrelost posljedično pruža teoretski smisleno međustanje između transformacijske aktivnosti i organizacijskih ishoda, odražavajući stupanj u kojem su transformacijski napori pretvoreni u organizacijske sposobnosti koje potom mogu podržati prilagodbu, inovacije i stvaranje vrijednosti (Teece, 2007; Leso i sur., 2024; Jie i sur., 2025).

# 7. DISKUSIJA

Središnji cilj ovog rada bio je razjasniti konceptualnu razliku između digitalne transformacije i digitalne zrelosti te objasniti njihov odnos. Analiza dostupne

literature dovodi do tri glavna zaključka. Prvo, literatura pruža dovoljno dokaza o konceptualnoj dvosmislenosti i preklapanju, ali to se ne smije pretjerivati s univerzalnom jednakošću. Postojeći radovi zrelost različito pozicioniraju kao spremnost za transformaciju, napredak unutar transformacijskog puta, prethodnika ishoda transformacije ili stanje koje proizlazi iz digitalnog razvoja (Teichert, 2019; Nasiri i sur., 2022; Hamberg, 2022; Aras i Büyüközkan, 2023). Stoga, problem nije u tome što literatura uvijek identificira ova dva konstrukta, već u tome što njihov vremenski i uzročni odnos nije dovoljno specificiran.

Drugo, razlika između procesa i stanja pruža efikasan način rješavanja ove dvosmislenosti. Digitalna transformacija opisuje organizacijske promjene koje se događaju tijekom vremena. Digitalna zrelost opisuje konfiguraciju sposobnosti koja proizlazi iz prethodnog organizacijskog razvoja u određenom trenutku. Ova razlika ne podrazumijeva da je digitalna zrelost statična. Stanje se može promijeniti. Umjesto toga, to znači da zrelost opisuje organizaciju u određenom trenutku, dok transformacija opisuje proces kroz koji se to stanje mijenja.

Treće, dinamičke sposobnosti pružaju mehanizam koji povezuje konstrukte. Transformacija uključuje eksperimentiranje, učenje, integraciju i rekonfiguraciju. Kada te aktivnosti proizvode ugrađene organizacijske rutine i sposobnosti, one doprinose zrelosti. Nakon što se akumuliraju, te sposobnosti utječu na sposobnost poduzeća da prepozna relevantne tehnološke i tržišne promjene, iskoristi novonastale prilike i ponovno se rekonfigurira (Teece, 2007; Warner & Wäger, 2019; Konopik i sur., 2022; Leso i sur., 2024).

Doprinos predloženog okvira stoga treba pažljivo pozicionirati u odnosu na nedavna istraživanja. Leso i sur. (2024) već pružaju važnu integraciju dinamičkih sposobnosti i digitalne zrelosti te identificiraju sposobnosti koje leže u osnovi digitalno zrelih organizacija. Originalnost koja se ovdje tvrdi stoga nije u tome da dinamičke sposobnosti, digitalna transformacija i digitalna zrelost nikada prije nisu bile povezane.

Umjesto toga, doprinos leži u eksplicitnom izražavanju njihovih vremenskih i kauzalnih pozicija putem razlikovanja procesa i stanja te njihovom integracijom u rekurzivni mehanizam, predstavljen konceptualnim modelom kao na sljedećoj slici. Povratna veza je ključna – digitalna zrelost se ne konceptualizira kao odredište na kojem transformacija završava već predstavlja platformu sposobnosti s koje daljnja transformacija postaje moguća.

To dovodi do središnje tvrdnje: Digitalno zrela poduzeća nisu organizacije koje su dovršile digitalnu transformaciju; to su organizacije koje su razvile sposobnosti potrebne za ponovljenu transformaciju. Ovo tumačenje također usklađuje naizgled različite kauzalne pozicije u novijim istraživanjima. Radovi koji tretiraju zrelost kao posljedicu transformacije i studije koje tretiraju zrelost kao prethodnicu naknadne organizacijske prilagodbe ne moraju nužno proturječiti jedna drugoj. One mogu promatrati različite faze istog rekurzivnog procesa.

**Slika 3. Konceptualni model strateškog zanavljanja digitalne zrelosti**

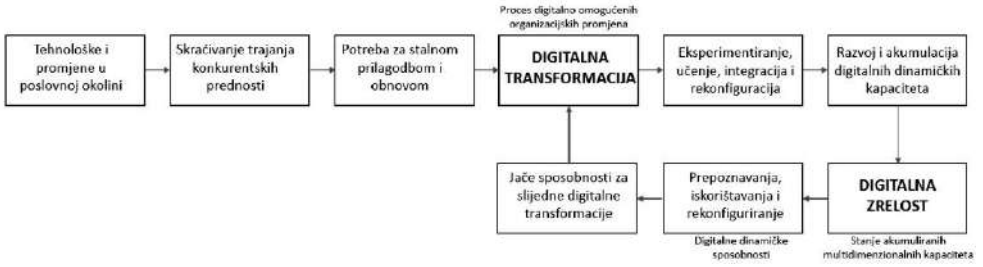


Često spominjana sve izraženija privremenost konkurentskih prednosti dodatno jača ovo tumačenje. S obzirom na sve brže tehnološke i tržišne promjene, digitalna zrelost ne smije se smatrati za trajno organizacijsko postignuće već kao stanje sposobnosti koje vremenom postaje neadekvatno i čija strateška vrijednost ovisi o kontinuiranoj obnovi.

# 8. TEORIJSKE I MENADŽERSKE IMPLIKACIJE

## 8.1. Teorijske implikacije

Prvi teorijski doprinos odnosi se na jasnoću ova dva konstrukta. Odvajanje digitalne transformacije kao procesa od digitalne zrelosti kao stanja smanjuje rizik konceptualne kružnosti u kojoj se transformacija mjeri kroz zrelost, dok se zrelost istovremeno tumači kao napredak transformacije.

Drugi doprinos je vremenski. Razlika između procesa i stanja uspostavlja vremenski poredak koji čini kauzalnu analizu smislenijom. Transformacijske aktivnosti odvijaju se kroz vrijeme i mogu promijeniti stanje organizacijskih sposobnosti; zrelost bilježi to stanje u određenom trenutku.

Treće, okvir pruža objašnjenje ishoda digitalne transformacije temeljeno na mehanizmu koji pomaže objasniti zašto sama tehnološka ulaganja mogu biti nedovoljna za poboljšanje performansi:

**Slika 4. Mehanizam konverzije digitalnih rezultata u poslovne rezultate**

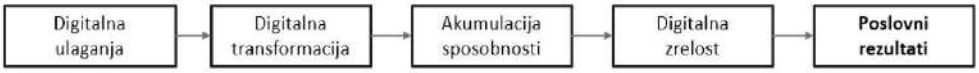


Četvrto, rad jača integraciju između istraživanja digitalne transformacije i teorije dinamičkih sposobnosti. Transformacija se tumači kao proces kroz koji se razvijaju i rekonfiguriraju organizacijske sposobnosti, dok zrelost bilježi njihovu akumuliranu višedimenzionalnu konfiguraciju (Teece, 2007; Warner & Wäger, 2019; Konopik i sur., 2022).

Peti, model povezuje digitalnu zrelost s privremenim karakterom konkurentskih prednosti. Ako određeni izvori konkurentske prednosti erodiraju, strateška važnost zrelosti leži manje u uspostavljanju trajno superiornog organizacijskog stanja, a više u stvaranju kapaciteta za ponovljenu obnovu (D'Aveni i sur., 2010; Dagnino i sur., 2021).

Konačno, rekurzivni model pruža moguće usklađivanje različitih kauzalnih interpretacija obrađenih u suvremenim istraživanjima. Digitalna transformacija može razviti digitalnu zrelost, dok akumulirana zrelost može potom ojačati dinamičke sposobnosti i olakšati daljnju transformaciju (Leso i sur., 2024; Jie i sur., 2025).

## 8.2. Praktične implikacije

Potreba za boljim razumijevanjem odnosa između digitalne transformacije i digitalne zrelosti nije samo konceptualna već i gospodarski iznimno značajna. Poduzeća diljem svijeta nastavljaju ulagati značajne i rastuće resurse u digitalnu transformaciju, uz predviđanje kako će globalna ulaganja u digitalnu transformaciju doseći gotovo 4 bilijuna dolara do 2028. (Yahnyuk, 2025), no ostvarivanje očekivane vrijednosti od tih ulaganja ostaje stalan izazov. Nedavno istraživanje BCG-a potvrđuje prethodne nalaze kako ukupne stope uspjeha transformacijskih inicijativa ostaju na približno 30–35% (Hamane, 2026). Važno je napomenuti da uspješna provedba projekta ne mora nužno

osigurati ostvarenje namjeravane poslovne vrijednosti niti ostavlja organizaciju bolje pozicioniranom za naknadnu transformaciju. Ovaj stalni jaz između digitalnih ulaganja, isporuke projekta i ostvarene organizacijske vrijednosti ističe temeljni upravljački izazov: tehnološka ulaganja ne prevode se automatski u organizacijske sposobnosti i poboljšane performanse. Razumijevanje kako se transformacijske inicijative pretvaraju u takve sposobnosti – i kako se te sposobnosti akumuliraju kao digitalna zrelost – stoga je ključno za objašnjenje zašto značajna digitalna ulaganja mogu proizvesti znatno različite organizacijske ishode.

Stoga pojašnjena konceptualna razlika ima nekoliko implikacija i za menadžersku praksu. Prvo, poduzeća bi trebala izbjegavati izjednačavanje uspjeha transformacije s uspješnom implementacijom tehnologije. Relevantno menadžersko pitanje ne smije biti je li tehnologija uspješno implementirana, već koje je organizacijske sposobnosti to ulaganje stvorilo ili ojačalo.

Drugo, procjene digitalne zrelosti trebale bi se prije svega koristiti kao dijagnostika nedostataka u sposobnostima po dimenzijama. Višedimenzionalna priroda zrelosti znači da poduzeće može biti tehnološki napredno, ali ograničeno vodstvom, upravljanjem, kvalitetom podataka, kulturom, vještinama ili organizacijskim dizajnom (Teichert, 2019; Aras i Büyüközkan, 2023; Senna i dr., 2023).

Treće, transformacijskim portfeljima trebalo bi se upravljati kao portfeljima razvoja sposobnosti, a ne primarno kao portfeljima projekata, čime se smanjuje rizik od proglašenja transformacije uspješnom samo zato što je projekt isporučen na vrijeme i unutar proračuna.

Konačno, rekurzivni model implicira da menadžment ne bi trebao težiti „dovršetku“ digitalne transformacije. Strateški cilj je uspostaviti organizacijsku sposobnost za kontinuiranu transformaciju. U okruženju koje karakterizira brzi tehnološki razvoj i kratki vijek trajanja konkurentskih prednosti, ta sposobnost u konačnici može biti vrjednija od bilo koje pojedinačne tehnologije implementirane kroz određeni program transformacije.

**Slika 5. Upravljanje transformacijskim projektima kroz mjerenje unaprjeđenja sposobnosti**

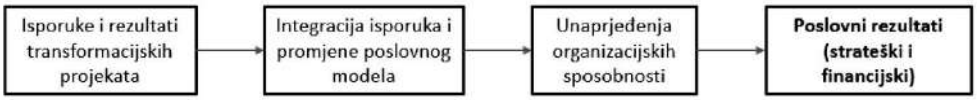


# 9. OGRANIČENJA I SMJERNICE ZA BUDUĆA ISTRAŽIVANJA

Konceptualni okvir razvijen u ovom radu ima nekoliko ograničenja koja ujedno daju smjernice za buduća istraživanja. Prvo, rad se temelji na strukturiranom integrativnom konceptualnom pregledu, a ne na iscrpnom sustavnom pregledu literature. Izvori su odabrani prema teorijskoj relevantnosti za četiri toka literature, a ne putem sveobuhvatnog pretraživanja baza podataka osmišljenog za identifikaciju svih radova koji obrađuju digitalnu transformaciju i digitalnu zrelost. Posljedično, rad ne može utvrditi koliko su određene definicije ili uzročna tumačenja prevladavajuće u cjelokupnoj literaturi.

Buduća istraživanja mogla bi provesti sustavni pregled posebno usmjeren na konceptualni i operativni odnos između digitalne transformacije i digitalne zrelosti. Takva istraživanja mogla bi klasificirati radove prema tome tretira li se zrelost kao prethodnik, mjera procesa, faza transformacije, posrednik, moderator ili ishod te time empirijski mapirati ovdje identificiranu konceptualnu dvosmislenost.

Drugo, predloženi odnos proces-stanje je teoretski izveden, a ne empirijski testiran. Iako nedavna istraživanja podržavaju važne elemente modela, potpuni rekurzivni niz nije testiran kako je formuliran u ovom radu. Buduća empirijska istraživanja stoga bi trebala operacionalizirati digitalnu transformaciju i digitalnu zrelost kao odvojene konstrukte i testirati vode li transformacijske aktivnosti do naknadnog povećanja digitalne zrelosti kroz organizacijsko učenje i razvoj sposobnosti.

Treće, digitalna zrelost konceptualizirana je kao višedimenzionalno stanje sposobnosti, ali se ne ispituje relativni doprinos pojedinačnih dimenzija zrelosti. Strategija, tehnologija, podaci, upravljanje, organizacijska kultura, orijentacija na kupca, procesi i ljudske kompetencije mogu se razvijati različitim brzinama i mogu različito doprinositi naknadnom trans-

formacijskom kapacitetu. Buduća istraživanja mogla bi ispitati funkcioniraju li određene dimenzije kao preduvjeti, uska grla ili akceleratori transformacije te je li uravnotežena zrelost u svim dimenzijama važnija od visoke zrelosti u pojedinim područjima.

Četvrto, predloženi mehanizam može varirati ovisno o industriji, veličini poduzeća, intenzitetu tehnoloških promjena i dinamici tržišta. Jie i sur. (2025), na primjer, ispituju visokotehnološka mala i srednja poduzeća, dok Senna i sur. (2023) usredotočuju se na proizvodnju i Industriju 4.0. Odnosi uočeni u tim okruženjima mogu se razlikovati u visoko reguliranim industrijama, profesionalnim uslugama, javnim poduzećima ili industrijama koje doživljavaju niže razine digitalnih poremećaja.

Konačno, tvrdnja da digitalna zrelost može erodirati zaslužuje posebno empirijsko istraživanje. Postojeći modeli zrelosti često podrazumijevaju progresivno kretanje prema višim fazama. Ovdje naglašena perspektiva privremenosti konkurentskih prednosti umjesto toga sugerira da vrijednost kapaciteta može opadati kako se tehnologije i konkurentski uvjeti mijenjaju.

# 10. ZAKLJUČAK

Digitalne tehnologije preoblikuju temelje konkurentskog nadmetanja u većini industrija ubrzavanjem inovacija, omogućavanjem novih poslovnih modela i načina komunikacije te doprinosom eroziji postojećih konkurentskih prednosti. U takvim uvjetima, poduzećima su digitalne tehnologije sve potrebnije ne same po sebi, već kao način razvoja sposobnosti kontinuirane strateške i organizacijske prilagodbe (D'Aveni i sur., 2010; Bharadwaj i sur., 2013; Dagnino i sur., 2021). Ovaj rad bavi se jednim od konceptualnih pitanja unutar ovoga šireg izazova: razlikom i odnosom između digitalne transformacije i digitalne zrelosti.

Postojeća istraživanja pokazuju konceptualnu bliskost i djelomično preklapajuće operacionalizacije dvaju konstrukata. Digitalna zrelost tumači se kao spremnost za transformaciju, napredak na putu transformacije, faza transformacije, prethodnik organizacijskih ishoda i rezultirajuće organizacijsko stanje (Teichert, 2019; Nasiri i sur., 2022; Hamberg, 2022; Aras i Büyüközkan, 2023). Umjesto zaključka da se konstrukti univerzalno tretiraju kao identični, rad tvrdi da njihove vremenske i uzročne granice zahtijevaju veću preciznost.

Predložena razlika je jednostavna. Digitalna transformacija je kontinuirani proces digitalno omogućenih organizacijskih promjena kroz koje poduzeća rekonfiguriraju strategije, resurse, strukture, procese, rutine i poslovne modele. Digitalna zrelost je akumulirano višedimenzionalno stanje organizacijskih digitalnih sposobnosti koje proizlaze iz uspješnih transformacijskih napora.

Teorija dinamičkih sposobnosti pruža mehanizam koji ih povezuje. Transformacija uključuje prepoznavanje prilika za promjene, mobilizaciju resursa, eksperimentiranje, organizacijsko učenje, integraciju i rekonfiguraciju. Kada te aktivnosti generiraju sposobnosti koje se ugrađuju u organizaciju, one doprinose digitalnoj zrelosti (Teece, 2007; Warner & Wäger, 2019; Konopik i sur., 2022; Leso i sur., 2024).

Odnos je također rekurzivan. Akumulirana digitalna zrelost pruža jaču osnovu za naknadno prepoznavanje i iskorištavanje prilika te rekonfiguraciju resursa, a time može povećati kapacitet poduzeća za daljnju transformaciju. Nedavna empirijska istraživanja koja pokazuju veze između zrelosti i dinamičkih sposobnosti u skladu su s ovim recipročnim tumačenjem (Jie i sur., 2025).

Digitalna zrelost stoga se ne bi trebala tumačiti kao krajnja točka digitalnog transformacijskog putovanja. Niti se transformacija treba shvaćati kao konačan projekt koji vodi prema trajno transformiranoj organizaciji. Umjesto toga, digitalna transformacija predstavlja kontinuirani proces razvoja i obnavljanja sposobnosti, dok digitalna zrelost predstavlja akumulirano stanje sposobnosti iz kojeg postaje moguća daljnja transformacija.

Sve privremenija priroda konkurentskih prednosti vodi k tome da digitalna zrelost nije trajno dosegnuto stanje već digitalno zrelo poduzeće mora nastaviti s transformacijom kako bi zadržalo zrelost. Ova perspektiva mijenja temeljno pitanje kroz koje treba procijeniti učinkovitost ulaganja u digitalne transformacije. Relevantno pitanje nije koliko je poduzeće uložilo, koliko je tehnologija implementiralo ili koliko je transformacijskih projekata dovršilo. Ključno pitanje jest je li transformacija učinila poduzeće sposobnijim za trajnu prilagodbu prepoznavanjem i iskorištavanjem tržišnih i tehnoloških promjena. Ako nije, digitalna ulaganja možda su proizvela tehnološku modernizaciju bez odgovarajuće organizacijske transformacije. Ako jest, transformacija je pridonijela akumulaciji digitalne zrelosti i stoga organizacijskom kapacitetu potrebnom za ponovljenu prilagodbu.

Prezentirani okvir ostaje konceptualan i zahtijeva empirijsku validaciju. Longitudinalno istraživanje, eksplicitno odvajanje mjera transformacije i zrelosti, usporedbe među industrijama i istraživanje erozije kapaciteta predstavljaju posebno važne sljedeće korake. Takva istraživanja mogu utvrditi pruža li ovdje predloženi odnos proces-stanje i rekurzivni odnos robusno objašnjenje kako poduzeća pretvaraju napore digitalne transformacije u trajni kapacitet za promjene.

# LITERATURA

Aras, A., & Büyüközkan, G. (2023). Digital transformation journey guidance: A holistic digital maturity model based on a systematic literature review. *Systems, 11*(4), 213. https://doi.org/10.3390/systems11040213

Bharadwaj, A., El Sawy, O. A., Pavlou, P. A., & Venkatraman, N. (2013). Digital business strategy: Toward a next generation of insights. *MIS Quarterly, 37*(2), 471–482.

D'Aveni, R. A., Dagnino, G. B., & Smith, K. G. (2010). The age of temporary advantage. *Strategic Management Journal, 31*(13), 1371–1385.

Dagnino, G. B., Picone, P. M., & Ferrigno, G. (2021). Temporary competitive advantage: A state-of-the-art literature review and research directions. *International Journal of Management Reviews, 23*(1), 85–115. https://doi.org/10.1111/ijmr.12242

Eisenhardt, K. M., & Martin, J. A. (2000). Dynamic capabilities: What are they? *Strategic Management Journal, 21*(10–11), 1105–1121.

Hamane, H. (2026, January 26). *Why 70% of transformations miss the mark and how to fix them*. BCG Platinion.

Hamberg, L. (2022). What is digital transformation and digital maturity? *Academy of Management Proceedings, 2022*(1), 18172. https://doi.org/10.5465/AMBPP.2022.18172abstract

Jie, H., Gooi, L. M., & Lou, Y. (2025). Digital maturity, dynamic capabilities and innovation performance in high-tech SMEs. *International Review of Economics & Finance, 99*, 103971. https://doi.org/10.1016/j.iref.2025.103971

Konopik, J., Jahn, C., Schuster, T., Hoßbach, N., & Pflaum, A. (2022). Mastering the digital transformation through organizational capabilities: A conceptual framework. *Digital Business, 2*(2), 100019. https://doi.org/10.1016/j.digbus.2021.100019

Leso, B. H., Cortimiglia, M. N., Ghezzi, A., & Minatogawa, V. (2024). Exploring digital transformation capability via a blended perspective of dynamic capabilities and digital maturity: A pattern matching approach. *Review of Managerial Science, 18*(4), 1149–1187. https://doi.org/10.1007/s11846-023-00692-3

Nasiri, M., Saunila, M., & Ukko, J. (2022). Digital orientation, digital maturity, and digital intensity: Determinants of financial success in digital transformation settings. *International Journal of Operations & Production Management, 42*(13), 274–298. https://doi.org/10.1108/IJOPM-09-2021-0616

Senna, P. P., Barros, A. C., Bonnin Roca, J., & Azevedo, A. (2023). Development of a digital maturity model for Industry 4.0 based on the technology-organization-environment framework. *Computers & Industrial Engineering, 185*, 109645. https://doi.org/10.1016/j.cie.2023.109645

Teece, D. J. (2007). Explicating dynamic capabilities: The nature and microfoundations of (sustainable) enterprise performance. *Strategic Management Journal, 28*(13), 1319–1350.

Teichert, R. (2019). Digital transformation maturity: A systematic review of literature. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis, 67*(6), 1673–1687. https://doi.org/10.11118/actaun201967061673

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.

Vial, G. (2019). Understanding digital transformation: A review and a research agenda. *The Journal of Strategic Information Systems, 28*(2), 118–144.

Warner, K. S. R., & Wäger, M. (2019). Building dynamic capabilities for digital transformation: An ongoing process of strategic renewal. *Long Range Planning, 52*(3), 326–349.

Westerman, G., Bonnet, D., & McAfee, A. (2014). *Leading digital: Turning technology into business transformation*. Harvard Business Review Press.

Wiggins, R. R., & Ruefli, T. W. (2005). Schumpeter's ghost: Is hypercompetition making the best of times shorter? *Strategic Management Journal, 26*(10), 887–911.

Winter, S. G. (2003). Understanding dynamic capabilities. *Strategic Management Journal, 24*(10), 991–995.

Yahnyuk, M. (2025, May 27). *Navigating digital transformation amid economic uncertainty*. International Data Corporation.

# DIGITAL TRANSFORMATION AND DIGITAL MATURITY: CONCEPTUAL DISTINCTIONS AND THEIR INTERRELATIONSHIP

***Abstract***

***Purpose****. Digital transformation and digital maturity have become prominent concepts in research and managerial practice, but their conceptual boundaries and mutual relationship remain insufficiently clear, which is one of the possible reasons for the poor efficiency of continuously growing digital investments (Yahnyuk, 2025, Hamane, 2026). The aim of this paper is to differentiate between the two constructs and develop a theoretically based explanation of their relationship.*

***Methodology.*** *The paper adopts a structured integrative conceptual review and theoretical synthesis. It integrates four complementary streams of literature: digital transformation, digital maturity, dynamic capabilities, and temporary competitive advantage. Seminal contributions are combined with recent studies that explicitly connect organizational capabilities, transformation processes, and digital maturity. The literature is analyzed through a process–state perspective and synthesized using dynamic capabilities theory as the principal theoretical lens.*

***Findings.*** *The analysis indicates that digital transformation and digital maturity should be treated as related but distinct organizational phenomena. Digital transformation is conceptualized as an ongoing process of digitally enabled organizational change through which firms reconfigure strategies, resources, structures, processes, routines, and business models. Digital maturity represents the accumulated multidimensional state of organizational digital capabilities emerging from successful transformation efforts. The relationship is not purely linear: transformation contributes to capability accumulation and higher maturity, while accumulated maturity subsequently strengthens the organization's capacity for further transformation. This recursive mechanism helps explain why technology investment and transformation activity do not automatically translate into organizational performance.*

***Originality and contribution.*** *The paper contributes to conceptual clarity by developing an explicit process–state distinction between digital transformation and digital maturity and integrating it with dynamic capabilities and temporary competitive advantage. It further proposes a*

*recursive capability-development model linking transformation, organizational learning, capability accumulation, maturity, and subsequent transformation.*

***Limitations.*** *As a conceptual study based on an integrative rather than systematic literature review, the proposed relationships are not empirically tested. Future research should operationalize the constructs separately, test the proposed process–state relationship longitudinally, and examine whether the mechanism varies across industries, firm sizes, and levels of environmental dynamism.*

***Keywords:*** *digital transformation, digital maturity, dynamic capabilities, temporary competitive advantage, organizational capabilities, digital technologies.*

ISSN 1849-6482