

DOPRINOSI ISTRAŽIVANJU FINANCIJA: TEORIJA I EMPIRIJA /

*CONTRIBUTIONS TO
INQUIRY INTO FINANCE:
THEORY AND EMPIRICS*

UREDNICI:

**GORDAN DRUŽIĆ
DRAŽEN KOŠKI
HRVOJE SERDARUŠIĆ**



EFOS

DOPRINOSI ISTRAŽIVANJU FINANCIIJA: TEORIJA I EMPIRIJA /
CONTRIBUTIONS TO INQUIRY INTO FINANCE: THEORY AND EMPIRICS

Urednici:

GORDAN DRUŽIĆ, DRAŽEN KOŠKI, HRVOJE SERDARUŠIĆ

Izdavači:

Hrvatska akademija znanosti i umjetnosti
Trg Nikole Šubića Zrinskog 11, 10 000 Zagreb

Sveučilište Josipa Jurja Strossmayera u Osijeku

Ekonomski fakultet u Osijeku

Trg Ljudevita Gaja 7, 31 000 Osijek

Za izdavača:

akademik Dario Vretenar, *Hrvatska akademija znanosti i umjetnosti*

prof. dr. sc. Boris Crnković, dekan, *Ekonomski fakultet u Osijeku*

Urednici:

akademik Gordan Družić, *Hrvatska akademija znanosti i umjetnosti*

izv. prof. dr. sc. Dražen Koški, *Ekonomski fakultet u Osijeku*

doc. dr. sc. Hrvoje Serdarušić, *Ekonomski fakultet u Osijeku*

Recenzenti:

prof. dr. sc. Gordana Kordić, *Ekonomski fakultet – Zagreb*

prof. dr. sc. Goran Karanović, *Fakultet za menadžment u turizmu i ugostiteljstvu, Opatija*

izv. prof. dr. sc. Domagoj Karačić, *Ekonomski fakultet u Osijeku*

izv. prof. dr. sc. Josip Visković, *Ekonomski fakultet u Splitu*

Slog, prijelom, dizajn korica i tisak

Krešendo, obrt za grafičke usluge, Osijek

Lektura hrvatskoga teksta:

Maja Perišin, mag. philol. croat.

Lektura engleskoga teksta:

Denis Pavić, prof.

ISBN 978-953-253-215-9 (tiskano izdanje)

ISBN 978-953-253-214-2 (elektroničko izdanje - PDF)

CIP zapis dostupan je u računalnom katalogu Gradske i sveučilišne
knjižnice Osijek pod brojem 151027024.

Odobreno Odlukom Fakultetskog vijeća Ekonomskog fakulteta u Osijeku, klasa: 007-02/24-01/02, ur.
broj: 2158-96-01-24-143 na 1. sjednici održanoj 31. listopada 2024. godine

Objavljivanje ove knjige financijski je pomoglo
Ministarstvo znanosti, obrazovanja i mladih Republike Hrvatske.

Za stavove iznesene u ovoj knjizi odgovorni su autori i ti stavovi ne moraju izražavati stavove izdavača.

© Sva prava pridržana. Nijedan dio ovog djela ne smije se reproducirati ni prenositi ni u kojem obliku
bez prethodne pisane suglasnosti autora.

HRVATSKA AKADEMIJA ZNANOSTI I UMJETNOSTI
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
EKONOMSKI FAKULTET U OSIJEKU

UREDNICI:

AKADEMIK GORDAN DRUŽIĆ

IZV. PROF. DR. SC. DRAŽEN KOŠKI

DOC. DR. SC. HRVOJE SERDARUŠIĆ

DOPRINOSI ISTRAŽIVANJU
FINANCIJA: TEORIJA
I EMPIRIJA /
*CONTRIBUTIONS TO
INQUIRY INTO FINANCE:
THEORY AND EMPIRICS*



Osijek, 2024.

SADRŽAJ

Predgovor	7

DIO 1: JAVNE FINACIJE I POREZNA POLITIKA PODUZEĆA

1. OCJENA EFIKASNOSTI JAVNIH RASHODA HRVATSKIH ŽUPANIJA METODOM ANALIZE OMEĐIVANJA PODATAKA	11
prof. dr. sc. Alemka Šegota, dr. sc. Robert Matić, prof. dr. sc. Helena Blažić Pečarić	
2. USPOREDNA ANALIZA CARINSKOG I TROŠARINSKOG TRETMANA KAVE U EU-U I BIH	37
izv. prof. dr. sc. Lejla Lazović-Pita, Maida Tahirović, MA	
3. DISKRECIJSKO PRAVO I PRAVEDNOST U KONTEKSTU TRANSFERNIH CIJENA	59
prof. dr. sc. Ivo Mijoč, dr. sc. Dubravka Kopun, doc. dr. sc. Ivan Čevizović	

DIO 2: BANKARSTVO, KAPITALNI ZAHTJEVI I ESG RIZICI

4. POSLJEDICE USKLAĐIVANJA S KAPITALNIM ZAHTJEVIMA – ZAŠTITA OD RIZIKA ILI OKIDAČ RIZIČNIJEG PONAŠANJA BANAKA?	89
prof. dr. sc. Ana Kundid Novokmet	
5. UTJECAJ BASELA IV NA KAPITALNE ZAHTJEVE ZA TRŽIŠNE RIZIKE	117
dr. sc. Bojan Tomić, prof. dr. sc. Saša Žiković, Lorena Jovanović, mag. oec.	
6. ESG RIZICI U BANKOVNOM SEKTORU: BIBLIOMETRIJSKA ANALIZA LITERATURE	141
izv. prof. dr. sc. Ana Ivanišević Hernaus, izv. prof. dr. sc. Branka Tuškan Sjauš	

DIO 3: FINANCIJSKA STABILNOST I KRIZNE SITUACIJE

7. PREDVIĐANJE FINANCIJSKE NESTABILNOSTI ODABRANIH POSLOVNIH SUBJEKATA U POSTPANDEMIJSKOM RAZDOBLJU	173
izv. prof. dr. sc. Siniša Bogdan	
8. UTJECAJ BOLESTI COVID-19 NA PRIVATE EQUITY TRŽIŠTE U CEE REGIJI	193
Anamarija Mlikotić, univ. bacc. oec., izv. prof. dr. sc. Marija Šimić Šarić	

DIO 4: EFIKASNOST POSLOVANJA PODUZEĆA

9. VREDNOVANJE RELATIVNE EFIKASNOSTI POSLOVANJA HRVATSKIH
 PODUZEĆA TRGOVINE NA MALO 217
 izv. prof. dr. sc. Andrea Arbula Blecich
10. ODREDNICE DRŽANJA NOVCA S OBZIROM NA DJELATNOST I
 VELIČINU PODUZEĆA U REPUBLICI HRVATSKOJ 235
 Romina Antić, mag. oec., izv. prof. dr. sc. Ivana Tomas Žiković, izv. prof. dr. sc. Kazi
 Sohag

DIO 5: INVESTICIJE I FINANCIJSKA ODRŽIVOST

11. ODRŽIVA ULAGANJA: IZAZOVI INTEGRACIJE ESG KRITERIJA
 U POSLOVNU STRATEGIJU 265
 izv. prof. dr. sc. Mihovil Anđelinović
12. FINANCIJSKI ASPEKTI PLAVE EKONOMIJE UNUTAR
 PERSPEKTIVE EU-A 281
 izv. prof. dr. sc. Sonja Brlečić Valčić, Marijana Jerić, mag. oec., doc. dr. sc. Jurica
 Bosna
13. UTJECAJ INFLACIJE NA CIJENE DIONICA U REPUBLICI HRVATSKOJ 307
 izv. prof. dr. sc. Dražen Koški
14. PREGLED IZRAVNIH STRANIH ULAGANJA U TURIZMU NA
 GLOBALNOJ RAZINI 321
 prof. dr. sc. Elvis Mujačević
15. RAČUNOVODSTVO POSLOVNIH KOMBINACIJA DRUŠTAVA POD
 ZAJEDNIČKOM KONTROLOM 343
 dr. sc. Branka Remenarić, doc. dr. sc. Ivan Čevizović, izv. prof. dr. sc. Branimir Skoko

DIO 6: FINANCIJSKA PISMENOST I BIHEVIORALNE FINACIJE

16. KOMPARATIVNA ANALIZA FINANCIJSKE PISMENOSTI UČENIKA
 SREDNJIH ŠKOLA U HRVATSKOJ, BOSNI I HERCEGOVINI
 I CRNOJ GORI 361
 izv. prof. dr. sc. Tonči Svilokos, izv. prof. dr. sc. Iris Lončar
17. UTJECAJ BIHEVIORALNIH PRISTRANOSTI NA EFEKT KRDA 385
 dr. sc. Natali Brmalj
18. BIHEVIORISTIČKE SPOZNAJE U POREZNOJ POLITICI 403
 prof. dr. sc. Renata Perić, izv. prof. dr. sc. Emina Jerković

PREDGOVOR

Interkatedarski skupovi katedri za financije ekonomskih fakulteta u Republici Hrvatskoj imaju dugogodišnju povijest. Ovi skupovi nastali su u želji za jačanjem međusobne znanstvene suradnje članova spomenutih katedri. Jedan od prvih organizatora, ali i idejnih začetnika ovih skupova bio je osječki profesor, prof. dr. sc. Branimir Marković koji nas je prerano napustio ove godine. Zbog realizacije ove ideje, ali i brojnih ugodnih i korisnih druženja s profesorom tijekom skupova, prof. dr. sc. Branimir Marković ostat će u lijepom sjećanju kako nas urednika tako i svih ostalih sudionika ovih susreta. Interkatedarski skupovi organiziraju se tako da je svake godine drugi ekonomski fakultet domaćin i organizator. Osim članova katedri za financije ekonomskih fakulteta diljem Republike Hrvatske, na skupu često sudjeluju i ugledni gosti iz Bosne i Hercegovine, ponajprije s Ekonomskoga fakulteta Sveučilišta u Mostaru i Ekonomskoga fakulteta Sveučilišta u Sarajevu.

Zbirna znanstvena knjiga *Doprinosi izučavanju financija: teorija i empirija* nastala je kao rezultat ideje prezentirane na interkatedarskom skupu održanom u Osijeku 2023. godine. Ova urednička znanstvena knjiga sastoji se od 18 poglavlja svrstanih u šest tematskih cjelina: 1) Javne financije i porezna politika poduzeće, 2) Bankarstvo, kapitalni zahtjevi i ESG rizici, 3) Financijska stabilnost i krizne situacije, 4) Efikasnost poslovanja poduzeća, 5) Investicije i financijska održivost i 6) Financijska pismenost i bihevioralne financije. Knjiga je prošla četverostruku recenziju i s obzirom na njezin višestruki znanstveni doprinos, svi recenzenti kategorizirali su je u kategoriju znanstvene knjige.

Knjiga je namijenjena znanstvenicima i stručnjacima iz područja ekonomije, bilo da se bave teorijskim ili empirijskim istraživanjima ili praktičnim aspektima poslovanja. Osim toga, bit će korisna i studentima na svim razinama ekonomskog obrazovanja za daljnje proširivanje znanja. Također, knjiga će koristiti i široj javnosti zainteresiranoj za ekonomsku znanost.

Iskreno zahvaljujemo svim autorima na njihovim vrijednim doprinosima koji su značajno uveličali kvalitetu ove knjige. Posebnu zahvalnost izražavamo recenzentima za trud i vrijeme posvećeno temeljitoj recenziji. Također zahvaljujemo Zavodu za znanstveni i umjetnički rad Hrvatske akademije znanosti i umjetnosti u Osijeku na nesebičnoj podršci pri suizdavaštvu ove knjige. Posebno zahvaljujemo i dekanu Ekonomskoga fakulteta u Osijeku na njegovoj organizacijskoj pomoći i podršci.

Urednici



DIO 1: JAVNE FINANCIJE I POREZNA POLITIKA PODUZEĆA

OCJENA EFIKASNOSTI JAVNIH RASHODA HRVATSKIH ŽUPANIJA METODOM ANALIZE OMEĐIVANJA PODATAKA¹

prof. dr. sc. Alemka Šegota

Sveučilište u Rijeci, Ekonomski fakultet
e-mail: alemka.segota@efri.uniri.hr

dr. sc. Robert Matić

Maroni d.o.o.
e-mail: osiguranje@maroni.hr

prof. dr. sc. Helena Blažić Pečarić

Sveučilište u Rijeci, Ekonomski fakultet
e-mail: helena.blazic.pecaric@efri.uniri.hr

SAŽETAK

Neravnomjerna gospodarska razvijenost u Republici Hrvatskoj predstavlja složen problem te je nužno utvrditi optimalnu razinu i način trošenja proračunskih sredstava kako bi se ostvario što veći gospodarski rast. U ovom se radu utvrđuju efikasne i neefikasne županije (uključivo s gradovima i općinama na njihovu području) za razdoblje 2017. - 2019. Primjenjuje se analiza omeđivanja podataka (AOMP) sa svrhom detektiranja optimalnog korištenja proračunskih sredstava kako bi se ostvario što veći ekonomski rast na regionalnoj razini, odnosno razini cijele Republike Hrvatske. Županije koje su u cijelom razdoblju efikasne jesu Brodsko-posavska županija, Krapinsko-zagorska županija, Međimurska županija, Varaždinska županija i Grad Zagreb. Ličko-senjska je županija u cijelom razdoblju na posljednjem mjestu. Utvrđen je i blagi porast prosječne efikasnosti hrvatskih županija. Za županije koje nisu efikasne određeni su izvori i iznosi neefikasnosti. Kako bi se olakšao prijelaz iz neefikasne u

¹ Rad je financiran projektom Sveučilišta u Rijeci *Interrelation between financial integration, sectoral divergence and real convergence - In search of a sustainable model and policy for the EU post-transition countries* (ZIP-UNIRI-2023-6).

efikasnu županiju vrlo je važno vidjeti primjere dobre prakse, odnosno utvrditi referentnu županiju. Varaždinska je županija referentna za čak osam županija, uključivo i Ličko-senjsku, što znači da za te županije predstavlja potencijalni uzor dosizanja efikasnosti.

Ključne riječi: *efikasnost, ekonomski rast, jedinice područne (regionalne) samouprave, analiza omeđivanja podataka*

JEL klasifikacija: H72, 023, R11. C02, C61

1. UVOD

Za ostvarivanje općeg društvenog blagostanja, kako u svijetu tako i u Republici Hrvatskoj (RH), jedinice lokalne i regionalne samouprave zajedno s javnim funkcijama vlasti postaju sve važniji čimbenik. Javne funkcije, primjerice opća uprava, komunalne djelatnosti, prostorno uređenje i urbanizam, zdravstvo, obrazovanje, socijalna zaštita ili kultura, na direktan i indirektan način utječu na standard građana i kvalitetu njihova života unutar jedinica lokalne samouprave. Kako bi se javne funkcije obavljale na efikasan način na nižim razinama vlasti, potrebna je kvalitetna i učinkovita fiskalna decentralizacija, čiji su konceptijski okvir postavili još relativno davno Stigler (1957), Musgrave (1959), Oates (1972) te Brennan i Buchanan (1980). Jedan je od ključnih razloga provedbe fiskalne decentralizacije potreba za efikasnim upravljanjem javnim financijama nižih razina vlasti.

Proračunski rashodi imaju vrlo važnu ulogu u podršci, odnosno ostvarivanju ekonomskog rasta. Učinkovito usmjeravanje proračunskih sredstava, i tekućih i kapitalnih rashoda, može potaknuti gospodarski rast. Kroz kapitalna ulaganja (rashodi za nabavu nefinancijske imovine) koja su namijenjena održavanju i izgradnji infrastrukture, kao što su primjerice ceste, zdravstvene ustanove, škole, sportski objekti, energetske sustavi, ostvaruju se preduvjeti za ostvarivanje gospodarske aktivnosti. Kroz ovakvu vrstu trošenja proračunskih sredstava ne samo da se poboljšavaju uvjeti za poslovanje već se stvaraju i dodatna radna mjesta, što može privući investicije i potaknuti rast. Isto tako i tekuća potrošnja (rashodi poslovanja) kroz usmjeravanje sredstava u obrazovanje, poticanje malih i srednjih poduzeća putem različitih programa, poput subvencija, poreznih olakšica i mentorstva, pružanje kvalitetnih socijalnih usluga mogu povećati ljudski kapital, poticati inovacije i pokrenuti ekonomsku aktivnost. Pružanje kvalitetnih socijalnih usluga, poput zdravstva i socijalne skrbi, može poboljšati

produktivnost radne snage. Zdravi i obrazovani građani skloniji su sudjelovati u gospodarskom životu, što dugoročno podržava ekonomski rast.

Analiza načina na koji se troše javna sredstva pomaže identificirati potencijalne neefikasnosti i nepravilnosti. Učinkovito upravljanje proračunskim resursima može povećati efikasnost programa i projekata te osigurati da se postižu optimalni rezultati. Proučavanje načina trošenja javnih rashoda važno je sredstvo za ostvarivanje odgovornog i transparentnog upravljanja javnim financijama. No, rashodi jedinice područne (regionalne) samouprave (JLPRS) često su usmjereni prema postizanju i određenih društvenih ili primjerice ekoloških ciljeva. Ciljevi JLPRS-a mogu varirati ovisno o njihovim specifičnostima i potrebama, a ekonomske, društvene i teritorijalne okolnosti igraju važnu ulogu u oblikovanju prioriteta, no poticanje gospodarskog rasta i razvoja zajednički je cilj svih jedinica. Proučavanje trošenja proračunskih sredstava pomaže osigurati da se sredstva usmjeravaju prema prioritetima te da se postižu željeni rezultati. Analiza pomaže identificirati nepotrebne troškove, potencijalna nepotrebna dupliranja i gubitke koji se mogu smanjiti ili eliminirati. Ovo je važno za očuvanje ograničenih resursa i optimizaciju proračuna.

Neravnomjerna gospodarska razvijenost u RH predstavlja složen problem te je nužno utvrditi optimalnu razinu i način trošenja proračunskih sredstava kako bi se ostvario što veći ekonomski rast. Često se ističe i neefikasno trošenje sredstava u lokalnim jedinicama, odnosno kako sredstva nisu optimalno iskorištena ili nisu usmjerena prema prioritetima i potrebama zajednice. To je razlog da se na temelju dostupnih podataka sagleda, konzistentno analizira i istraži problematika efikasnosti jedinica lokalne samouprave i utjecaj efikasnosti na ekonomski rast jedinica lokalne samouprave.

Tijekom posljednjih 30 godina izrađen je velik broj empirijskih studija koje su se usredotočile na procjenu efikasnosti lokalnih i regionalnih samouprava tako da raste i broj radova s njihovim sintetičkim pregledima (Narbón-Perpiñá i De Witte, 2018; Aiello i Bonanno, 2019; Rueda López *et al.*, 2020; Johnsson *et al.*, 2021; Mergoni i De Witte, 2022; Milán-García *et al.*, 2022). Ovakve se studije počinju javljati i u RH (Škuflić *et al.*, 2010; Rabar i Blažević, 2011; Škuflić *et al.*, 2013; Hunjet *et al.*, 2014; Rabar i Grbin 2019). Najveći broj studija, kako u svijetu tako i u RH, koristi analizu omeđivanja podataka (AOMP) (engl. *Data Envelopment Analysis* – DEA).

Efikasnost održava sposobnost postizanja ciljeva u odnosu na resurse uložene za ostvarivanje ciljeva i ishoda. Mjeri se odnosom rezultata (engl. *outputa*) i

uloženih resursa (engl. *inputa*), te se pokazatelji rezultata uglavnom odnose na proizvedena dobra i usluge stvorene putem različitih aktivnosti. Efikasnost je postignuta kad nije moguće povećati rezultate uz korištenje uloženih resursa, odnosno resursi se koriste efikasno kada nije moguće ostvariti veće koristi, kvalitetu i/ili bolje rezultate njihovom upotrebom (Slijepčević, 2009). Istraživanja tematike efikasnosti započela su sredinom 20. stoljeća pa je tako Farrell (1957) proučavao mjerenje tehničke efikasnosti na primjeru poljoprivredne proizvodnje u Sjedinjenim Američkim Državama i došao do zadovoljavajuće mjere efikasnosti, na osnovi koje je moguće izmjeriti efikasnost s više ulaza ili više izlaza. Predmetni rad bio je temelj za kasniji razvoj metoda i tehnika mjerenja efikasnosti, a posebno AOMP (engl. *Data Envelopment Analysis* – DEA), koju su razvili Charnes *et al.* (1978) na temelju Farrellovih pretpostavki. Analiza omeđivanja podataka predstavlja središnju metodu i tehniku u nizu analiza efikasnosti i produktivnosti kada se uspoređuju razna društva, regije i zemlje. Traži se najuspješnija jedinica koja će služiti kao primjer nabolje prakse i koja će biti na granici efikasnosti. Zatim se mjeri efikasnost preostalih jedinica promatranja i gleda se koliko je ista neefikasna, odnosno kolika je njezina udaljenost od granice efikasnosti ili od jedinice koja se smatra efikasnom. Cilj je izračunati koliko smanjiti razinu utrošenog *inputa*, bez smanjenja ostvarenog *outputa* ili koliko određena neefikasna jedinica promatranja može uvećati svoj *output*, bez povećanja *inputa*. Radi se o projekcijama na granicu efikasnosti za svaku relativno neefikasnu jedinicu. Na temelju odabranih adekvatnih ulaznih i izlaznih varijabli za mjerenje efikasnosti jedinica lokalne samouprave u širem smislu u RH i dobivenih rezultata mjerenja, ovo istraživanje analizira i utvrđuje relevantne značajke odnosa efikasnosti ovih jedinica.-

Svrha istraživanja je doprinijeti daljnjem razvoju znanstvenih činjenica i empirijski argumentirati saznanja o efikasnosti jedinica lokalne samouprave i doprinijeti racionalnijem i svrsishodnijem korištenju javnih resursa u RH. U slučaju ovog rada jedinice promatranja bit će županije u širem smislu u RH. Promatranjem lokalne samouprave u širem smislu obuhvaćaju se sve razine samouprave koje su ustrojene unutar jednog sustava (općinska, gradska, županijska, regionalna, pokrajinska i druge razine ako postoje), a u užem smislu lokalna samouprava odnosi se samo na prvu (najnižu) razinu samouprave u određenoj zemlji (Matić, 2023, str. 134). Prema navedenom znači da se pod pojmom županije u širem smislu podrazumijevaju općine i gradove te županije, odnosno sva utrošena proračunska sredstva na području određene županije. S obzirom na to da je RH administrativno podijeljena na dvadeset županija i Grad Zagreb koji ima status grada i županije, oni predstavljaju 21 jedinicu promatranja čija se relativna efikasnost procjenjuje na temelju tri *inputa* i jednim *outputom*.

Nakon što je razmatran širok spektar relevantnih pokazatelja, posebice na temelju ekstenzivnog pregleda korištenih *inputa* i *outputa* u prethodnim istraživanjima (Narbón-Perpiñá i De Witte, 2018), ali i nekim istraživanjima za RH (Rabar i Grbin, 2019; Škuflić *et al.*, 2013) kao *inputi* odabrani su tekući rashodi (rashodi poslovanja) (TEKP), rashodi za nabavu nefinancijske imovine (investicije) (RNNI) i trošak plaća (rashodi za zaposlene) (TRP), a kao *output* bruto domaći proizvod. Sve se varijable promatraju po glavi stanovnika.

Podaci su preuzeti od Državnog zavoda za statistiku (DZS) i podataka iz Izvještaja o prihodima i rashodima, primicima i izdacima (PR-RAS) županija, općina i gradova za razdoblje 2002. – 2020. godine sa stranica Ministarstva financija Republike Hrvatske. Podaci se odnose na razdoblje od 2017. godine do 2019. godine.

Nakon uvodnog dijela rada, gdje je izbor metode i posebice varijabli potkrijepljen prethodnim empirijskim istraživanjima, u drugom dijelu rada prezentiran je pregled literature i varijable koje su na temelju navedenoga izabrane za ovo istraživanje. U trećem dijelu iznosi se metodologija rada – osnovni modeli AOMP-a i pojmovi na kojima se temelje dobiveni rezultati. Nakon toga u četvrtom dijelu slijede rezultati s paralelnom diskusijom. U zaključnom se dijelu, uz sintezu rezultata, iznose ograničenja istraživanja i otvaraju mogućnosti za daljnja istraživanja.

2. PREGLED LITERATURE I IZBOR VARIJABLI

Tijekom posljednjih 30 godina kontinuirano raste, posebice od 2015. godine (Milán-García *et al.*, 2022, str. 2880), broj empirijskih studija koje su se usredotočile na procjenu efikasnosti lokalnih i regionalnih samouprava (npr. Afonso i Fernandes, 2003; Borge i Naper, 2006; Giménez i Prior, 2007; Borge i ostali, 2007; Lo Storto, 2016; Arneil i Villaroman, 2019; Afonso i Venâncio, 2020; Çağlar Onbaşıoğlu, 2021; Balaguer-Coll *et al.*, 2022; Tran i Dollery, 2023; Ayuba *et al.*, 2023; Perugini, 2024; Bucci *et al.*, 2024). Dobiveni podaci uglavnom ukazuju na to da je razina neučinkovitosti uglavnom veća u onim sredinama gdje su prihodi viši te da je mehanizam dodjeljivanja financijske pomoći od strane središnje države (s ciljem smanjenja razlike u razinama prihoda između jedinica lokalnih vlasti) u negativnoj korelaciji s učinkovitosti tih jedinica. Navedene studije, kao i mnoge druge iz ovoga područja, najvećim dijelom primjenjuju AOMP, odnosno DEA-u, nakon koje slijedi njezina nekonveksna verzija – analiza slobodnog raspoređivanja resursa (Free Disposal Hull – FDH), te

ostale neparametrijske metode, dok se nešto rjeđe koriste parametrijske metode (Narbón-Perpiñá i De Witte, 2018; Aiello i Bonanno, 2019; Rueda López *et al.*, 2020; Johnsson *et al.*, 2021; Mergoni i De Witte, 2022; Milán-García *et al.*, 2022).

Brojnost ovih studija rezultira i sve većim brojem preglednih radova odnosno meta analiza ove tematike (Narbón-Perpiñá i De Witte, 2018; Aiello i Bonanno, 2019; Rueda López *et al.*, 2020; Mergoni i De Witte, 2022²; Milán-García *et al.*, 2022). Osim u SAD-u, najveći broj ovih istraživanja proveden je u Italiji, Španjolskoj i UK, nakon čega slijede Kina i Australija (Milán-García *et al.*, 2022, str. 2883).

AOMP, odnosno DEA metoda koristila se za analizu efikasnosti u raznim sektorima³ u RH⁴, uključivo i u javnom sektoru odnosno gradovima/općinama, te posebice županijama. Škuflić *et al.* (2010) su na uzorku 21 županije u RH utvrdili koje su županije efikasne, te koje resurse neefikasne županije trebaju efikasnije koristiti za povećanje regionalne, a time i ukupne nacionalne proizvodnje. Kao *input* varijable korištene su sljedeće: broj diplomiranih studenata, strane direktne investicije, iznos investicija za opremu, izvoz, broj poslovnih subjekata, dok su kao *output* varijable korištena sljedeća dva pokazatelja: bruto društveni proizvod i bruto plaće. Rabar i Blažević (2011) su u razdoblju od 2004. do 2008. identificirali učinkovite hrvatske županije u turističkom smislu, te su dobili podatke da je upravljanje turizmom u županijama svake godine sve učinkovitije. Rabar (2013) je primjenu AOMP-a za opću ekonomsku efikasnost hrvatskih županija korištenjem sedam ekonomskih varijabli (*inputi*: stopa ne-

² Mergoni i DeWitte (2022) imaju nešto drugačiji obuhvat – utjecaj eksternih intervencija, odnosno promjena politika na efikasnost, te njihov pregled literature obuhvaća najvećim dijelom javni sektor, uključivo i ekološke politike, ali i privatni (iako u puno manjem opsegu). Zanimljivo je, s obzirom na to da je AOMP dominantna metoda, da dinamika radova koji su ovdje obuhvaćeni slijedi već spomenuti uzorak – rast je kontinuiran zadnjih 30-ak godina i intenzivira se od 2015. godine (Mergoni i De Witte, 2022, str. 1340).

³ Posebno se ističe bankovni sektor – Jemrić i Vujčić (2002) su među prvima promatrali učinkovitost banaka u RH od 1995. do 2000. godine i zaključili da su banke u stranom vlasništvu u prosjeku najučinkovitije, a da su nove banke učinkovitije od starih. Čiković *et al.* (2021) su u pregledu radova o primjeni AOMP-a na bankovni sektor u RH potvrdili njihove zaključke. Osim toga, AOMP se koristio i prilikom analize u poljoprivredi (Bahovec i Neralić, 2001), šumarstvu (Šporčić *et al.*, 2007), trgovini (Šegota, 2008), javnim financijama na razini cijele RH (Slijepčević, 2009), te obrazovanju (npr. Arbula Blečić, 2020).

⁴ Neralić i Kedžo (2019) su, slično već spomenutim međunarodnim pregledima literature, izradili pregled i analizu primjene AOMP-a u Hrvatskoj, zaključivši kako se najviše primjenjivala u mjerenju efikasnosti/uspješnosti u ekonomiji i poslovnoj ekonomiji. I njihovi podaci ukazuju na kontinuirani rast radova, no ovdje posebice od 2009. godine (Neralić i Kedžo, 2019, str. 96).

zaposlenosti, broj primatelja socijalne pomoći; *outputi*: udio sekundarnog sektora u bruto dodanoj vrijednosti, bruto investicije u fiksni kapital, pokrivenost uvoza izvozom, broj diplomiranih studenata i BDP) proširila kategorijskim pristupom, kao i analizom prozora. Hunjet *et al.* (2014) mjerili su efikasnost 12 najvećih hrvatskih gradova, gdje su kao *input* varijable koristili broj zaposlenih i uloženu imovinu, a kao *output* dohodak. Rabar i Grbin (2019) potaknuli neravnomjernim gospodarskim rastom hrvatskih županija analiziraju njihovu usporednu efikasnosti koristeći šest pokazatelja pod dominantnim utjecajem fiskalne politike u razdoblju od 2002. do 2015. godine (uz BDP kao jedini *output*, *inputi* su porezni prihodi, tekući rashodi, kapitalni rashodi, broj zaposlenih u jedinicama lokalne i područne (regionalne) samouprave, te ukupan broj zaposlenih umanjeno za zaposlene u tijelima lokalne i područne samouprave i kod korisnika proračuna). Dobiveni rezultati efikasnosti potvrdili su postavljene hipoteze o značajnim nejednakostima među županijama. Škuflić *et al.* (2013) usporedili su RH s drugim europskim zemljama kako bi vidjeli koja zemlja najučinkovitije koristi svoje *inpute* kako bi poboljšala životni standard svojih građana. Kao *inpute* autori uzimaju produktivnost i izvoz (udio izvoza u BDP-u), a kao *output* BDP po glavi stanovnika te udjele bruto plaća i osobne potrošnje u BDP-u. Međutim, navedena istraživanja nisu promatrala kako potrošnja županija u širem smislu utječe na stvoreni BDP po glavi stanovnika u toj istoj jedinici, odnosno koliko efikasno lokalne jedinice u RH koriste sredstva koja imaju na raspolaganju.

Nakon što je pregledom literature razmatran širok spektar relevantnih pokazatelja, za istraživanje u ovom radu kao *inputi* su odabrani tekući rashodi (rashodi poslovanja) (TEKP), rashodi za nabavu nefinancijske imovine (investicije) (RNNI) i trošak plaća (rashodi za zaposlene) (TRP).

Tekući rashodi, odnosno rashodi poslovanja najčešće su korišteni ulazni pokazatelji za mjerenje troškova lokalnih samouprava za pružanje lokalnih usluga, što proizlazi i iz metaanalize Narbón-Perpiñá i De Witte (2018, str. 440), gdje se posebno ističu sljedeći autori: Eeckaut *et al.* (1993), Athanassopoulos i Triantis (1998), Sampaio de Sousa *et al.* (2005), Geys (2006), Ibrahim i Salleh (2006), Balaguer-Coll *et al.* (2007), Balaguer-Coll i Prior (2009), Kutlar i Bakirci (2012), Nikolov i Hrovatin (2013), Pacheco *et al.* (2014), Monkam (2014), Radulovic i Dragutinović (2015), Arcelus *et al.* (2015). Korišteni su i u nedavnom sličnom istraživanju i za hrvatske županije (Rabar i Grbin, 2019). Tekuća potrošnja odnosi se na troškove koji uglavnom proizlaze iz svakodnevnih aktivnosti, odnosno redovnih operacija. Tekuća potrošnja predstavlja bitan dio

financijskog upravljanja, a praćenje i kontrola ovih troškova ključni su za održavanje stabilnosti financijskog stanja organizacije ili pojedinca.

Input varijablu TRP (trošak plaća) su prema Narbón-Perpiñá i De Witte (2018, str. 440) koristili sljedeći autori: Hayes i Chang (1990), Worthington (2000), Balaguer-Coll *et al.* (2007), Benito *et al.* (2010), Liu *et al.* (2011), Kutlar i Bakirci (2012), Fogarty i Muga (2013), Nakazawa (2013), Cordero *et al.* (2016). Trošak plaća prikazuje *input* rada, te eventualno govori i imaju li određene jedinice prevelik ili premal broj zaposlenih. Slično nedavno istraživanje za hrvatske županije koristilo je broj zaposlenih (Rabar i Grbin, 2019).

Input varijabla RNNI (rashodi za nabavu nefinancijske imovine) odnosi se na kapitalne rashode, odnosno investicijske izdatke koje lokalne jedinice redovito ostvaruju, a prema Narbón-Perpiñá i De Witte (2018, str. 440) kao *input* varijabla korištena je u sljedećim radovima: Worthington (2000), Balaguer-Coll *et al.* (2007), Bosch-Roca *et al.* (2012), Kutlar i Bakirci (2012), Balaguer-Coll *et al.* (2013), Fogarty i Muga (2013), Bischoff *et al.* (2013), Cuadrado-Ballesteros *et al.* (2013), Da Cruz i Marques (2014). I slično nedavno istraživanje za hrvatske županije koristilo je kapitalne rashode (Rabar i Grbin, 2019). Kapitalna potrošnja često se koristi kao sredstvo za poticanje gospodarskog rasta i poboljšanje javne usluge. Ova vrsta potrošnje obično ima dugoročne posljedice i koristi, a može također imati pozitivan utjecaj na zaposlenost i opći razvoj zajednice. Za *input* rashoda za nabavu nefinancijske imovine u istraživanju ovoga rada uzet je prosjek ostvarenog rashoda po stanovniku kao trogodišnji prosjek koji prethodi promatranoj godini.

Podjela rashoda izrađena je na opisani način kako bi se obuhvatili svi značajni rashodi koje kreiraju JLPRS, a u svrhu izvršavanja zadataka unutar svoje nadležnosti u razdoblju od godine dana, i kako bi se prikazao utjecaj kapitalnih investicija koje su, zajedno s radnom snagom, prema mnogim teorijama i modelima endogenog rasta među najrelevantnijima (Scott, 1991).

Output je izražen bruto domaćim proizvodom po glavi stanovnika (BDPpc) što su koristili u svojim radovima sljedeći autori: Rao i Coelli (1998), Krüger *et al.* (2000), Škuflić *et al.* (2013), Cherchye *et al.* (2011), Pastor *et al.* (2018), Rabar i Grbin (2019), Marto *et al.* (2022).

Kako bi usporedba bila što pouzdanija, a imajući u vidu velike razlike među županijama, u dijelu koji je rezultat velikih razlika u broju stanovnika, sve se varijable u istraživanju ovoga rada promatraju po glavi stanovnika.

3. METODOLOGIJA

Problematika preispitivanja efikasnosti jedna je od najdiskutabilnijih u suvremenoj znanosti o primjeni matematičkih metoda u ekonomskoj analizi. Pojam efikasnosti nije strogo definiran pa je podložan različitim interpretacijama i mjerenjima. U radu se koristi Analiza omeđivanja podataka (AOMP) kao relativno nova metodologija koju su 1978. godine Charnes, Cooper i Rhodes predložili kao rješenje problema ocjene efikasnosti neprofitnih organizacija, odnosno državnih škola u Sjedinjenim Američkim Državama. Metodologija je ubrzo nakon toga doživjela široku primjenu u raznovrsnim područjima kao što su bankarski i financijski sektor, trgovina, zdravstveni sustavi, razne industrije, turizam, sport itd. Razlog za tako široku primjenu leži u tome što kod ocjene efikasnosti donositelja odluka (DO) nije potrebno poznavati egzaktnu funkcijsku vezu između višestrukih *inputa* koji predstavljaju resurse koji se koriste i *outputa* kao ostvarenih rezultata. To ne znači da takva veza ne postoji, dapače, pozitivna korelacijska veza između *inputa* i *outputa* potvrđuje tu vezu i predstavlja pretpostavku uspješne primjene. AOMP koristi matematičko programiranje koje omogućuje uporabu velikog broja varijabli i ograničenja na specifičan način, što olakšava rješavanje kompleksnih problema. Nadalje, *inputi* i *outputi* mogu biti izraženi u različitim mjernim jedinicama i općenito se očekuje manje *inputa* koji se koriste da bi se ostvarile što veće količine *outputa*. Pojam efikasnosti je tako definiran kao omjer dobivenog i uloženog pa je jedan od najvažnijih koraka kod postavljanja modela AOMP-a adekvatan odabir *inputa* i *outputa*. U nastavku se prikazuju osnovni modeli AOMP-a, definicije i pojmovi na kojima se temelje dobiveni rezultati.-

3.1. CCR MODEL

Jedan od temeljnih modela AOMP-a jest model CCR (s pretpostavkom konstantnog prinosa), čija je osnovna ideja u tome da se, nakon formiranja virtualnih *inputa* i *outputa* uz pomoć pripadnih težina, odrede težine koje maksimiziraju njihov omjer. Pretpostavlja se da su na raspolaganju podaci o n donositelja odluke (DO) koji koriste m *inputa* i realiziraju s *outputa*. U ovom su radu donositelji odluka županije koje se međusobno uspoređuju kako bi se odredila relativna efikasnost svake od njih. Vrijednosti za „težine“ *inputa* (v_i) ($i = 1, \dots, m$) i „težine“ *outputa* (u_r) ($r = 1, \dots, s$) bit će rješenja modela razlomljenog programiranja koji slijedi.

$$\max \quad \theta = \frac{u_1 y_{10} + u_2 y_{20} + \dots + u_s y_{s0}}{v_1 x_{10} + v_2 x_{20} + \dots + v_m x_{m0}} \quad (1.1)$$

uz uvjete

$$\frac{u_1 y_{1j} + \dots + u_s y_{sj}}{v_1 x_{1j} + \dots + v_m x_{mj}} \leq 1 \quad (j = 1, \dots, n) \quad (1.2)$$

$$v_1, v_2, \dots, v_m \geq 0 \quad (1.3)$$

$$u_1, u_2, \dots, u_s \geq 0 \quad (1.4)$$

Ograničenja znače da omjer „virtualnih *outputa*“ i „virtualnih *inputa*“ ne smije prijeći vrijednost 1, za svaki DO. Cilj je odrediti težine (v_i) i (u_r) koje maksimiziraju omjer koji odgovara donosiocu odluke DO_0 koji se ocjenjuje. Ako je optimalna vrijednost $\theta^* = \max \theta = 1$, postignuta je efikasnost za pripadni DO, dok vrijednost manja od 1 znači da se radi o neefikasnosti. Gornji se model može zamijeniti sljedećim ekvivalentnim linearnim modelom (Cooper, Seiford, Tone, 2000, str. 23.).

$$\max \quad \theta = \mu_1 y_{10} + \dots + \mu_s y_{s0} \quad (1.5)$$

$$\text{uz uvjete} \quad v_1 x_{10} + \dots + v_m x_{m0} = 1 \quad (1.6)$$

$$\mu_1 y_{1j} + \dots + \mu_s y_{sj} \leq v_1 x_{1j} + \dots + v_m x_{mj} \quad (j = 1, \dots, n) \quad (1.7)$$

$$v_1, v_2, \dots, v_m \geq 0 \quad (1.8)$$

$$\mu_1, \mu_2, \dots, \mu_s \geq 0 \quad (1.9)$$

Definicija 1. (CCR – efikasnost)

1. DO_0 je CCR-efikasan ako je $\theta^* = 1$ i postoji barem jedan optimalni (v^*, u^*) s $v^* > 0$ i $u^* > 0$.

2. Inače je DO_0 CCR-neefikasan.

CCR-neefikasnost implicira da je ili $\theta^* < 1$ i slijedi da postoji barem jedan DO za koje bi se θ^* mogao povećati. Neka je skup takvih $j \in \{1, \dots, n\}$

$$E'_0 = \left\{ j : \sum_{r=1}^s u_r^* y_{rj} = \sum_{i=1}^m v_i^* x_{ij} \right\} \quad (1.10)$$

Tada se podskup E'_0 skupa E_0 koji se sastoji od CCR-efikasnih DO zove *referentni* skup od DO_0 . Nadalje, skup koji je razapet s E_0 zove se *efikasna granica* od DO_0 .

Definicija 2.

DO je potpuno efikasan ako i samo ako nije moguće poboljšati nijedan input ili output bez pogoršanja nekog drugog inputa ili outputa.

Sljedeća definicija odnosi se na referentni skup koji čine svi efikasni DO.

Definicija 3.

Za neefikasnog DO_0 definira se njegov referentni skup E_0 , baziran na rješenju najveće dopunske varijable s:

$$E_0 = \{j | \lambda_j^* > 0\} \quad (j \in \{1, \dots, n\}) \quad (1.11)$$

Navedene relacije sugeriraju da se efikasnost od (x_0, y_0) za DO_0 može poboljšati ako se vrijednosti *inputa* smanje proporcionalno s omjerom θ^* i uklone viškovi *inputa* zabilježeni u s^{-*} . Analogno, efikasnost može biti dostignuta ako se vrijednosti *outputa* povećaju s manjkovima *outputa* u s^{+*} .

Sljedeća formula za poboljšanje poznata je pod nazivom *CCR-projekcija*:

$$\hat{x}_0 = x_0 - \Delta x_0 = \theta^* x_0 - s^{-*} \leq x_0 \quad (1.12)$$

$$\hat{y}_0 = y_0 + \Delta y_0 = y_0 + s^{+*} \geq y_0 \quad (1.13)$$

Projekcije *inputa* (1.12) odnosno *outputa* (1.13) na efikasnu granicu za sve neefikasne DO predstavljaju vrijedne informacije kod donošenja odluka koje *inpute* i za koliko smanjiti, ako se radi o modelu usmjerenom *inputima*, ili koje *outpute* i za koliko povećati, ako se radi o usmjerenju prema *outputima*. Naime, dostizanje efikasnosti može se promatrati tako da se uz iste razine *inputa* povećaju razine *outputa* ili da se ista razina *outputa* pokuša dostići uz istovremeno smanjenje korištenih *inputa*.

2.2. BCC MODEL

Pretpostavka BCC modela je, za razliku od CCR modela, varijabilni prinos, što se može očitati iz konkavnog i po dijelovima linearnog oblika proizvodne granice razapete konveksnom ljuskom postojećih DO. Banker, Charnes i Cooper (1984) razvili su model koji se od CCR modela razlikovao samo u dodatnom uvjetu $e\lambda = \sum_{j=1}^n \lambda_j = 1$. *Inputu* orijentirani BCC model ocjenjuje efikasnost DO_0 rješavanjem linearnog programa (u obliku ovojnice):

$$(BCC_0) \quad \min \quad \theta_b \quad (1.14)$$

$$\text{uz uvjete } \theta_B x_o - X\lambda \geq 0 \quad (1.15)$$

$$Y\lambda \geq y_o \quad (1.16)$$

$$e\lambda = 1 \quad (1.17)$$

$$\lambda \geq 0 \quad (1.18)$$

gdje je θ_B skalar.

U nastavku se navode definicije koje govore o BCC-efikasnosti, referentnom skupu i poboljšanim aktivnostima (Cooper, Seiford, Tone, 2000, str. 89-91).

Definicija 4.

Ako optimalno rješenje $(\theta_B^*, \lambda^*, s^{-*}, s^{+*})$ za (BCC_0) zadovoljava $\theta_B^* = 1$ i nema dopunskih varijabli ($s^{-*} = 0, s^{+*} = 0$), tada se DO_0 naziva BCC-efikasnim, inače je BCC-neefikasan.

Definicija 5.

Za BCC-neefikasn timer DO_0 definira se njegov referentni skup E_0 , baziran na optimalnom rješenju λ^* s:

$$E_0 = \{j | \lambda_j^* > 0\} \quad (j \in \{1, \dots, n\}) \quad (1.19)$$

Sada se formula za poboljšanje, odnosno BCC-projekcija može zapisati:

$$\hat{x}_o \Leftarrow \theta_B^* x_o - s^{-*} \quad (1.20)$$

$$\hat{y}_o \Leftarrow y_o + s^{+*} \quad (1.21)$$

Definicija 6.

DO koji ima najmanju vrijednost inputa za bilo koju jedinicu inputa ili najveću vrijednost outputa za bilo koju jedinicu outputa je BCC – efikasan.

Kad je BCC model *outputu* usmjeren, njegov je oblik:

$$\max \eta_B \quad (1.22)$$

$$\text{uz uvjete } X\lambda \leq x_o \quad (1.23)$$

$$\eta_B y_o - Y\lambda \leq 0 \quad (1.24)$$

$$e\lambda = 1 \quad (1.25)$$

$$\lambda \geq 0 \quad (1.26)$$

4. REZULTATI

Kao što je već istaknuto, odabir *inputa* i *outputa* predstavlja jedan od najvažnijih koraka u provedbi AOMP-a. Kod odabira *inputa*, objašnjenog detaljnije u Uvodu, tekuća potrošnja (rashodi poslovanja) (TEKP), rashodi za nabavu nefinancijske imovine (kapitalna potrošnja) (RNNI) i trošak plaća (rashodi za zaposlene) (TRP) – svi izraženi po stanovniku, adekvatni su pokazatelji resursa s kojima županije raspolažu, dok je kao najvažniji i jedini *output* odabran ostvareni bruto domaći proizvod po stanovniku (BDPpc) kako bi usporedba među županijama bila realna. Navedeni podaci uključeni su u analizu za razdoblje od 2017. do 2019. godine. Kapitalna potrošnja određena je kao zbroj kapitalnih potrošnji za prethodno trogodišnje razdoblje kako bi se uzelo u obzir vrijeme koje je potrebno za njezine efekte.

U odabiru *inputa* i *outputa* vodilo se računa o ograničenju analize koje kaže da ukupan broj *inputa* i *outputa* mora biti višestruko manji nego što je ukupan broj DO koje se ocjenjuju. Budući da je broj županija 21, radi veće diskriminatorne snage analize izabrana su ukupno tri *inputa* i jedan *output*, što je više od pet puta manji broj u odnosu na broj županija. Dobivene su vrijednosti korelacije, prikazane u Tablici 1., potvrdile opravdanost odabranih *inputa* i *outputa*. Najveći iznos korelacije između *inputa* i *outputa* iznosi približno 0,85 i to između tekuće potrošnje i ostvarenog bruto domaćeg proizvoda.

Tablica 1. Iznosi korelacija između *inputa* i *outputa*.

	INPUTI			OUTPUT
	RNNI	TEKP	TRP	BDPpc
RNNI	1	0,76263	0,84696	0,50808
TEKP	0,76263	1	0,82088	0,84907
TRP	0,84696	0,82088	1	0,52893
BDPpc	0,50808	0,84907	0,52893	1

Izvor: izračun autora na temelju podataka Državnog zavoda za statistiku, <https://podaci.dzs.hr/media/rihnbma3/bruto-domaci-proizvod.xlsx> [6. 8. 2023.] i Ministarstva financija, <https://mf.in.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/pr-ras-i-ras-funkc-za-razdoblje-2014-2020/3173> [5. 8. 2023.]

Što se tiče odabira modela i njihova usmjerenja primijenjena su oba osnovna modela na podatke o *inputima* i *outputu*. Usporedba dobivenih rezultata prikazana je u Tablici 2.

Tablica 2. Rezultati efikasnosti po modelu CCR i BCC za 2017. godinu.

Županija	BCC model		CCR model	
	Rezultat efikasnosti	Poredak	Rezultat efikasnosti	Poredak
Bjelovarsko-bilogorska	1	1	0,8727	5
Brodsko-posavska	1	1	0,7485	10
Dubrovačko-neretvanska	0,6838	18	0,6404	16
Istarska	0,8335	12	0,727	13
Karlovačka	0,8072	15	0,756	8
Koprivničko-križevačka	0,8188	13	0,7508	9
Krapinsko-zagorska	1	1	0,8215	6
Ličko-senjska	0,4645	21	0,4485	21
Međimurska	1	1	1	1
Osječko-baranjska	0,936	8	0,887	4
Požeško-slavonska	0,9402	7	0,6335	18
Primorsko-goranska	0,9054	9	0,8049	7
Sisačko-moslavačka	0,7673	17	0,6589	15
Splitsko-dalmatinska	0,7696	16	0,7334	12
Šibensko-kninska	0,6381	19	0,6337	17
Varaždinska	1	1	1	1
Virovitičko-podravska	0,8771	10	0,6141	20
Vukovarsko-srijemska	0,8527	11	0,6607	14
Zadarska	0,6199	20	0,6195	19
Grad Zagreb	1	1	1	1
Zagrebačka	0,8115	14	0,7338	11

Izvor: izračun autora na temelju podataka Državnog zavoda za statistiku, <https://podaci.dzs.hr/media/rihnbma3/bruto-domaci-proizvod.xlsx> [6. 8. 2023.] i Ministarstva financija, <https://mfim.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/pr-ras-i-ras-func-za-razdoblje-2014-2020/3173> [5. 8. 2023.]

Vidljivo je da se rezultati znatno razlikuju budući da je po BCC modelu 50 % više županija, tj. šest ocijenjeno kao relativno efikasno u odnosu na tri relativno efikasne županije po CCR modelu.


Navedeno se može objasniti efektom varijabilnog prinosa, odnosno po dijelovima linearne granice efikasnosti, što vodi zaključku da je BCC model odgovarajući, pa su i rezultati efikasnosti za razdoblje od 2017. do 2019. godine prikazani u Tablici 3. i Grafikonu 1. određeni na temelju BCC modela s usmjerenjem prema *inputima*.

Tablica 3. Rezultati efikasnosti i poredak za razdoblje 2017. – 2019. godine

	2017.		2018.		2019.	
Županija	Rezultat efikasnosti	Poredak	Rezultat efikasnosti	Poredak	Rezultat efikasnosti	Poredak
Bjelovarsko-bilogorska	1	1	0,9821	6	0,9753	6
Brodsko-posavska	1	1	1	1	1	1
Dubrovačko-neretvanska	0,6838	18	0,6919	19	0,7022	20
Istarska	0,8335	12	0,8392	13	0,8251	13
Karlovačka	0,8072	15	0,8343	14	0,8592	10
Koprivničko-križevačka	0,8188	13	0,8729	9	0,9331	7
Krapinsko-zagorska	1	1	1	1	1	1
Ličko-senjska	0,4645	21	0,4867	21	0,5435	21
Međimurska	1	1	1	1	1	1
Osječko-baranjska	0,936	8	0,9178	7	0,8967	8
Požeško-slavonska	0,9402	7	0,8671	10	0,8337	12
Primorsko-goranska	0,9054	9	0,8944	8	0,8395	11
Sisačko-moslavačka	0,7673	17	0,7604	17	0,7739	17
Splitsko-dalmatinska	0,7696	16	0,7837	15	0,8123	14
Šibensko-kninska	0,6381	19	0,7339	18	0,7345	18
Varaždinska	1	1	1	1	1	1
Virovitičko-podravska	0,8771	10	0,7733	16	0,8037	16
Vukovarsko-srijemska	0,8527	11	0,8451	12	0,8055	15
Zadarska	0,6199	20	0,6496	20	0,7271	19
Grad Zagreb	1	1	1	1	1	1
Zagrebačka	0,8115	14	0,846	11	0,8744	9
Prosječna vrijednost	0,844		0,8469		0,8543	

Izvor: izračun autora na temelju podataka Državnog zavoda za statistiku, <https://podaci.dzs.hr/media/rihnbma3/bruto-domaci-proizvod.xlsx> [6. 8. 2023.] i Ministarstva financija, <https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/pr-ras-i-ras-funkc-za-razdoblje-2014-2020/3173> [5. 8. 2023.]

Grafikon 1. Rezultati efikasnosti u razdoblju 2017. – 2019.



Izvor: izračun autora na temelju podataka Državnog zavoda za statistiku, <https://podaci.dzs.hr/media/rihnbma3/bruto-domaci-proizvod.xlsx> [6. 8. 2023.] i Ministarstva financija, <https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/pr-ras-i-ras-func-za-razdoblje-2014-2020/3173> [5. 8. 2023.]

Vidljivo je da su za većinu županija rezultati efikasnosti podjednaki ili bolji nego u prethodnom razdoblju, ali i da do znatnijih promjena tijekom trogodišnjeg razdoblja nije došlo.

Može se primijetiti da se prosječan rezultat efikasnosti županija lagano povećavao pa je tako za 2017. godinu iznosio 84,4 %, za 2018. godinu 84,7 %, dok za 2019. godinu iznosi cca 85,4 %. Prosječna vrijednost rezultata efikasnosti svih županija iznosi cca 85,43 %. Gotovo je nevjerovatno da su ovi rezultati skoro identični višegodišnjem prosjeku efikasnosti hrvatskih županija od 85,6 % u prethodnom sličnom istraživanju za razdoblje od 2002. do 2015. godine, iako navedeno istraživanje nije koristilo identične (iako slične) varijable⁵ (Rabar, Grbin, 2019), ali i višegodišnjem prosjeku efikasnosti hrvatskih županija od 84,92 % u ranijem istraživanju za RH koje je koristilo potpuno različite varijable (Škuflić *et al*, 2010).

⁵ Kao *input* varijable korišteni su porezni prihodi, tekući rashodi, kapitalni rashodi, broj zaposlenih u jedinicama lokalne i područje (regionalne) samouprave i ukupan broj zaposlenih umanjeno za zaposlene u tijelima lokalne i područne samouprave i kod korisnika proračuna. Kao *output* varijabla korišten je BDP. Svi su podaci stavljeni u odnos s brojem stanovnika.

Županije Brodsko-posavska, Krapinsko-zagorska, Međimurska, Varaždinska i Grad Zagreb efikasne su u cijelom razdoblju dok je Bjelovarsko-bilogorska županija postigla efikasnost 2017. godine i u narednom razdoblju bila vrlo blizu efikasnosti s rezultatom od skoro 98 % kad je zauzela 6. mjesto. Nasuprot najbolje ocijenjenim županijama jest Ličko-senjska koja je tijekom cijelog razdoblja na posljednjem mjestu s daleko ispodprosječnim rezultatom od oko 50 % efikasnosti. Navedeni su rezultati većim dijelom u skladu i s prethodnim istraživanjem za RH (Rabar i Grbin, 2019.) u kojem autori koriste slične *inpute* i isti *output*.

Projekcije na efikasnu granicu prikazane u Tablici 4., kao i referentni skup koji se nalazi u Tablici 5. također su određeni uz pretpostavku varijabilnog prinosa i to za posljednju godinu – 2019.

Tablica 4. Projekcije na efikasnu granicu.

Županija	Rezultat efikasnosti	Poredak	Podaci	Projekcije	Razlika %	Podaci	Projekcije	Razlika %	Podaci	Projekcije	Razlika %	Podaci	Projekcije	Razlika %
Bjelovarsko-bilogorska	0,9753	6	2008	1958,384	2,471	3856	3760,722	2,471	573,306	408,3507	28,773	68067,3	86204,33	26,646
Brodsko-posavska	1	1	2770	2769,98	0,001	2736	2735,988	0	509,904	509,8967	0,001	61042,1	61042,06	0
Dubrovačko-neretvanska	0,7022	20	3368	2364,988	29,781	6667	4681,525	29,781	848,721	480,3381	43,404	108393	108393,1	0
Istarska	0,8251	13	4978	2810,239	43,547	6118	5047,725	17,494	790,963	534,2056	32,461	118309	118308,8	0
Karlovačka	0,8592	10	2600	2233,947	14,079	3972	3412,784	14,079	562,13	442,8298	21,223	70910,7	77660,65	9,519
Koprivničko-križevačka	0,9331	7	2266	2114,478	6,687	3819	3563,632	6,687	491,19	427,8814	12,889	75003,5	81364,74	8,481
Krapinsko-zagorska	1	1	2538	2537,983	0,001	3051	3050,983	0,001	374,398	374,3957	0,001	66424,4	66424,37	0
Ličko-senjska	0,5435	21	4486	2438,326	45,646	6265	3405,286	45,646	1026,45	438,7842	57,252	79972,5	79972,52	0
Međimurska	1	1	3061	3061	0	3326	3326	0	433,14	433,1399	0	85067,1	85067,06	0
Osječko-baranjska	0,8967	8	2622	2351,233	10,327	3708	3325,084	10,327	655,79	450,3663	31,325	76108,8	76108,75	0
Požeško-slavonska	0,8337	12	3038	2532,914	16,626	3646	3039,831	16,626	549,738	458,3408	16,626	61255,3	68018,94	11,042
Primorsko-goranska	0,8395	11	4158	2853,713	31,368	5657	4749,271	16,046	735,546	516,6866	29,755	112547	112546,5	0
Sisačko-moslavačka	0,7739	17	2689	2081,111	22,607	4659	3605,762	22,607	589,138	423,7065	28,08	72402,6	82399,26	13,807
Šplitsko-dalmatinska	0,8123	14	2797	2272,112	18,766	4261	3461,376	18,766	636,542	436,1649	31,479	79817,9	79817,92	0
Šibensko-kninska	0,7345	18	3409	2504,066	26,545	4779	3510,393	26,545	663,12	424,7735	35,943	84427,3	84427,33	0
Varaždinska	1	1	1841	1841	0	3909	3909	0	393,665	393,6649	0	89845,2	89845,25	0
Virovitičko-podravska	0,8037	16	5007	2702,68	46,022	3518	2827,339	19,632	585,551	470,5948	19,632	58565	62602,6	6,894
Vukovarsko-srijemska	0,8055	15	2863	2306,05	19,453	4124	3321,743	19,453	818,013	451,8515	44,762	64382,5	75425,13	17,152
Zadarska	0,7271	19	3405	2475,739	27,291	4895	3559,101	27,291	649,252	419,6995	35,356	85752,3	85752,27	0
Zagreb	1	1	2372	2372	0	8056	8056	0	710,785	710,7854	0	176390	176389,8	0
Zagrebačka	0,8744	9	2526	2208,619	12,565	4009	3505,286	12,565	444,866	388,9701	12,565	79456,7	79456,75	0
Prosjeak	0,8543	10,5238	3085,81	2418,598	17,7992	4525,29	3802,611	14,5722	621,057	456,9251	22,93	84482,8	87487,06	4,4543
MAX	1	21	5007	3061	46,022	8056	8056	45,646	1026,45	710,7854	57,252	176390	176389,8	26,646
MIN	0,5435	1	1841	1841	0	2736	2735,988	0	374,398	374,3957	0	58565	61042,06	0
St Dev	0,1213	6,8383	894,932	305,9035	15,4868	1332,58	1140,189	12,1267	162,826	71,1624	16,778	26738,4	25199,22	7,4504

Izvor: autorov izračun na temelju podataka Državnog zavoda za statistiku, <https://podaci.dzs.hr/media/rihnmba3/bruto-domaci-proizvod.xlsx> [6. 8. 2023.] i Ministarstvo financija,

<https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/pras-i-ras-funkc-za-razdoblje-2014-2020/3173> [5. 8. 2023.]

Kao što se vidi u Tablici 4. za županije koje nisu efikasne određeni su izvori i iznosi neefikasnosti. Tako bi npr. Osječko-baranjska županija da dostigne efikasnost, trebala ostvarivati istu razinu BDP-a po stanovniku, uz niže razine svih *inputa* i to za cca 10 % niže vrijednosti rashoda za nabavu nefinancijske imovine, kao i tekuće potrošnje, a čak cca 31 % niže troškove plaća. To bi značilo da u odnosu na efikasne županije, ima viškove *inputa* u odnosu na ostvareni *output*, odnosno da koristi previše resursa s obzirom na ostvarene rezultate. Iako su projekcije određene na temelju inputima usmjerenom modelu neke županije ne mogu postići efikasnost samo uz njihovo smanjenje, nego je potrebno i povećati razinu *outputa* pa tako npr. Bjelovarsko-bilogorska županija nema toliko značajan višak od 2,5 % u razini rashoda za nabavu nefinancijske imovine, kao i u tekućoj potrošnji, ali zato je razina troškova plaća značajno veća za cca 29 %, dok je razina *outputa* preniska i trebala bi se povećati za cca 27 %. To znači da bi trebalo provesti proces optimizacije i efikasnog rasporeda ljudskih resursa u različitim sektorima lokalne administracije s ciljem smanjenja troškova i prilagodbe resursa potrebama lokalne zajednice, što će dovesti do veće efikasnosti.

Prosječna vrijednost rezultata efikasnosti svih županija iznosi cca 85,43 % i može se primijetiti da su županije koje su ostvarile rezultat iznad navedenog prosjeka sljedeće: Bjelovarsko-bilogorska, Brodsko-posavska, Karlovačka, Koprivničko-križevačka, Krapinsko-zagorska, Međimurska, Osječko-baranjska, Varaždinska, Grad Zagreb i Zagrebačka — njih deset od ukupno dvadeset i jedne županije, što čini gotovo polovicu. Županije koje su ostvarile rezultat efikasnosti ispod prosjeka jesu Dubrovačko-neretvanska, Istarska, Ličko-senjska, Požeško-slavonska, Primorsko-goranska, Sisačko-moslavačka, Splitsko-dalmatinska, Šibensko-kninska, Virovitičko-podravska, Vukovarsko-srijemska i Zadarska. Zanimljivo je da su među županijama s ispodprosječnim rezultatima i sve županije jadranskog dijela Republike Hrvatske. Nadalje, u prosjeku bi neefikasne županije trebale isti BDP ostvariti uz cca 18 % niže vrijednosti rashoda za nabavku nefinancijske imovine, 15 % niže vrijednosti tekuće potrošnje i čak 23 % niže troškove plaća kako bi postale relativno efikasne.

Ako promotrimo pojedine županije po sugeriranim smanjenjima pojedinih *inputa* vidimo da je deset županija s vrijednostima iznad prosjeka od 18 % za potrebno smanjenje rashoda za nabavku nefinancijske imovine i to Virovitičko-podravska 46 %, Ličko-senjska 45 %, Istarska 44 %, Primorsko-goranska 31 %, Dubrovačko-neretvanska 29 %, Zadarska 27 %, Šibensko-kninska 27 %, Sisačko-moslavačka 23 %, Vukovarsko-srijemska 20 % i Splitsko-dalmatinska 19 %.

Sljedećih deset županija imaju vrijednosti iznad prosjeka od 15 % za potrebno smanjenje tekuće potrošnje: Ličko-senjska 45 %, Dubrovačko-neretvanska 29 %, Zadarska 27 %, Sisačko-moslavačka 23 %, Virovitičko-podravska 20 %, Vukovarsko-srijemska 20 %, Splitsko-dalmatinska 19 %, Istarska 18 %, Požeško-slavonska 17 % i Primorsko-goranska 16 %.

Županija koje imaju vrijednosti iznad prosjeka od 23 % za potrebno smanjenje troškova plaća ima jedanaest, i to su Ličko-senjska 57 %, Vukovarsko-srijemska 45 %, Dubrovačko-neretvanska 43 %, Šibensko-kninska 36 %, Zadarska 35 %, Istarska 33 %, Splitsko-dalmatinska 32 %, Osječko-baranjska 31 %, Primorsko-goranska 30 %, Bjelovarsko-bilogorska 29 % i Sisačko-moslavačka 28 %.

Navedeni rezultati analize mogu biti vrlo korisni za donošenje odluka s ciljem povećanja rezultata efikasnosti, odnosno efikasnijeg korištenja raspoloživih resursa u ostvarivanju što boljih rezultata. Kako bi se olakšao prijelaz iz neefikasne u efikasnu županiju vrlo je važno vidjeti primjere dobre prakse, odnosno rezultate efikasnih županija, što omogućuje referentni skup. On se sastoji od efikasnih županija koje mogu poslužiti kao uzor neefikasnima i prikazan je u Tablici 5.

Tablica 5. Referentni skup županija.

Efikasna županija	Referentna županijama
Brodsko-posavska	Požeško-slavonska, Virovitičko-podravska, Vukovarsko-srijemska
Krapinsko-zagorska	Krapinsko-zagorska
Međimurska	Istarska, Primorsko-goranska, Šibensko-kninska, Zadarska
Varaždinska	Bjelovarsko-bilogorska, Dubrovačko-neretvanska, Karlovačka, Koprivničko-križevačka, Ličko-senjska, Osječko-baranjska, Sisačko-moslavačka, Splitsko-dalmatinska, Zagrebačka
Grad Zagreb	Grad Zagreb

Izvor: izračun autora

Varaždinska županija ima najvišu frekvenciju pojavljivanja u referentnom skupu odnosno referentna je za čak sljedećih osam županija: Bjelovarsko-bilogorsku, Dubrovačko-neretvansku, Karlovačku, Koprivničko-križevačku, Ličko-senjsku, Osječko-baranjsku, Sisačko-moslavačku, Splitsko-dalmatinsku, Zagrebačku i predstavlja za te županije potencijalni uzor dostizanja efikasnosti. Među njima je i najneefikasnija županija – Ličko-senjska, kao i prethodno istaknute Osječko-baranjska i Bjelovarsko-bilogorska. Slijedi Međimurska županija koja je referentna za četiri županije, među kojima su županije koje se uobičajeno smatraju uspješnima, kao što su Istarska i Primorsko-goranska, ali i najneefikasnije županije poslije Ličko-senjske – Zadarska, dok je Brodsko-po-

savska referentna za tri županije i to Požeško-slavonsku, Virovitičko-podravsku i Vukovarsko-srijemsku. Krapinsko-zagorska županija referentna je samoj sebi, kao i Grad Zagreb, što se može objasniti tako da ne mogu predstavljati potencijalne uzore za ostale županije zbog svojih specifičnosti.

4. ZAKLJUČAK

U radu je analizirana efikasnost hrvatskih županija, uključujući i njihove gradove i općine, za razdoblje od 2017. – 2019. godine koristeći analizu omeđivanja podataka (s naglaskom na BCC model). Kao *inputi* korišteni su tekući rashodi (rashodi poslovanja), rashodi za nabavu nefinancijske imovine (investicije) i trošak plaća (rashodi za zaposlene), dok je kao *output* korišten BDP. Sve su varijable izražene po glavi stanovnika.

Za većinu su županija u promatranom razdoblju rezultati efikasnosti isti, odnosno malo bolji iz godine u godinu. Nema znatnijih promjena tijekom trogodišnjeg razdoblja. Prosječan se rezultat efikasnosti županija lagano povećavao pa je tako za 2017. godinu iznosio 84,4 %, za 2018. godinu 84,7 %, dok za 2019. godinu iznosi cca 85,4 %. Ovi su podaci sukladni prethodnim istraživanjima za Hrvatsku.

Značajne utvrđene razlike u efikasnostima potvrđuju značajne regionalne nejednakosti u RH, što je sukladno i s prethodnim istraživanjima. Brodsko-posavska, Krapinsko-zagorska, Međimurska i Varaždinska županija, te Grad Zagreb su efikasni u cijelom razdoblju. Bjelovarsko-bilogorska županija bila je efikasna 2017. godine, te je iduće dvije godine bila vrlo blizu efikasnosti s rezultatom od skoro 98 %. Ličko-senjska županija je tijekom cijelog razdoblja na posljednjem mjestu s daleko ispodprosječnim rezultatom od ispod 50 % efikasnosti u prve dvije godine. No, i kod nje je vidljivo povećanje u zadnjoj godini na preko 54 %. I ovi su podaci vrlo slični prethodnom relevantnom istraživanju za RH.

Za županije koje nisu efikasne određeni su izvori i iznosi neefikasnosti. Tako je određeno za koliko bi pojedina županija za istu razinu BDP-a po stanovniku trebala smanjiti navedene *inpute*. Iako su projekcije određene na temelju *inputima* usmjerenog modela neke županije ne mogu postići efikasnost samo uz njihovo smanjenje nego je potrebno i povećati razinu *outputa*. Navedenom su analizom određeni i najvažniji izvori neefikasnosti.

Iako je AOMP najčešće korištena metoda u ovakvim istraživanjima, ona ima i određene nedostatke. Metodologija zahtijeva da ukupan broj *inputa* i *outputa*

ta ovisi o broju jedinica koje se uspoređuju na način da mora biti višestruko manji od broja jedinica koje se uspoređuju. Kako u RH postoji „samo“ 21 županija broj *inputa* i *outputa* relativno je mali. Ovo se istraživanje usredotočilo na najčešće korištene kategorije javnih rashoda u literaturi. No, jedno od otvorenih pitanja jest bi li uključivanje nekih drugih (npr. ukupnih rashoda umjesto tekućih) ili dodavanja još neke kategorije rashoda značajno utjecalo na rezultate. Isto tako bi vjerojatno ubacivanje dodatnih nefinancijskih varijabli javnog sektora (npr. zdravstvene ili neke druge usluge, površina) ili ekonomskih varijabli (npr. broj zaposlenih u županiji, investicije i sl.) imalo drugačije ishode. Umjesto BDP-a kao pokazatelj *outputa* mogao se koristiti i neki globalni indikator – npr. indeks razvijenosti, no ovdje ostaje uvijek otvoreno pitanje uključenja i adekvatnog ponderiranja relevantnih faktora. Sve navedeno otvara širok prostor budućih istraživanja.

Nadalje, ocjena efikasnosti se kod AOMP-a temelji na podacima iz prošlosti i ne uključuje vremensku varijablu, što metodu čini statičnom. Konačno, ona ocjenjuje relativnu, a ne apsolutnu efikasnost, što ponovno čini atraktivnijom mogućnost daljnjih istraživanja ovog tipa na razini većeg broja zemalja (npr. mediteranskih) odnosno EU-a ili čak i šire. Proširenjem skupa županija RH s odgovarajućim usporedivim područjima ostalih zemalja EU-a dobio bi se još bolji uvid u rezultat ostvarene efikasnosti jer bi se tada broj relevantnih *inputa* i *outputa* mogao povećati⁶.

Za daljnja bi istraživanja, temeljena npr. na različitim razinama razvoja županija, bilo korisno grupirati županije uz pomoć kategorijskih varijabli odnosno primijeniti *kategorijski pristup* kod ocjene efikasnosti i na taj način „izolirati“ utjecaj boljih uvjeta pojedinih županija na ostvarene rezultate efikasnosti.

Dodatno bi se, primjenom *analize prozora* s drugačijim varijablama⁷ otkrile promjene u efikasnosti tijekom određenog vremenskog razdoblja.

Mogla bi se ispitati i *vrsta prinosa* županija na temelju koje bi vlada mogla odlučiti o eventualnom povećanju *inputa* u slučaju rastućeg prinosa odnosno smanjenju *inputa* u slučaju opadajućeg prinosa.

Nadalje, tu je i mogućnost primjene SBM modela za određivanja superefikasnosti, koji bi odredio rang među efikasnim jedinicama tj. županijama.

⁶ Škuflić *et al.* (2013) pokušali su navedeno, a s relativno malim brojem *input* varijabli i istraživanje nije obuhvatilo fiskalne elemente.

⁷ Analiza prozora već je primijenjena u hrvatskim županijama, kao i u njihovoj usporedbi s EU-om kod Rabar (2013), Škuflić *et al.* (2013), te Rabar i Grbin (2019).

Rezultati analize mogu biti veoma korisni za efikasnije korištenje raspoloživih resursa u ostvarivanju što boljih rezultata. Kako bi županije napredovale iz neefikasne u efikasnu trebaju imati referentnu uzornu županiju. Najbolji uzor jest Varaždinska županija, koja je referentna za dostizanje efikasnosti za čak osam županija (Bjelovarsko-bilogorsku, Dubrovačko-neretvansku, Karlovačku, Koprivničko-križevačku, Ličko-senjsku, Osječko-baranjsku, Sisačko-moslavačku, Splitsko-dalmatinsku i Zagrebačku). Slijedi Međimurska županija koja je referentna za četiri županije (Istarsku, Primorsko-goransku, Šibensko-kninsku i Zadarsku). Brodsko-posavska županija uzor je za tri županije (Požeško-slavonsku, Virovitičko-podravsku i Vukovarsko-srijemsku). Krapinsko-zagorska županija i Grad Zagreb zbog svojih specifičnosti ne mogu predstavljati potencijalne uzore.

Ovo je istraživanje u mnogočemu potvrdilo rezultate prethodnih istraživanja za hrvatske županije. Buduća bi istraživanja trebala utvrditi relevantnost ovih rezultata kroz primjenu dodatnih modificiranih modela AOMP-a i provođenja analize prozora.

REFERENCE

1. Afonso, A. i Fernandes, S. (2003) Efficiency of Local Government Spending: Evidence from the Lisbon Region. *ISEG-UTL Economics Working Paper*, No. 9.
2. Afonso, A. i Venâncio, A. (2020) Local territorial reform and regional spending efficiency, *Local Government Studies*, Vol. 46, No. 6, str. 888-910, DOI: 10.1080/03003930.2019.1690995
3. Aiello, F., Bonanno, G. (2019) Explaining differences in efficiency: A meta study on local government literature, *Journal of Economic Surveys*, Vol. 33, No. 3, str. 999-1027. Dostupno na: <https://doi.org/10.1111/joes.12310> [6. ožujka 2024.]
4. Arbula Blečić, A. (2020) Čimbenici relativne efikasnosti visokoškolskih ustanova iz područja ekonomije, *Management (Split)*, Vol. 25, No. 1; str. 45-67. doi: 10.30924/mjcmi.25.1.3
5. Arneil, G. G. i Villaroman, N. S. (2019) Strategic performance management in local governments in the Philippines: work and rating challenges, *Asia Pacific Journal of Public Administration*, Vol. 41, No. 2, str. 119-125, DOI: 10.1080/23276665.2019.1631032
6. Ayoub, K., Duboz, M.-L. i Le Gallo, J. (2023) Assessing French departments' spending efficiency over time, *Applied Economics*, Vol. 55, NO. 59, str. 6939-6964, DOI: 10.1080/00036846.2023.2167925
7. Bahovec, V. i Neralić, L. (2001) Relative efficiency of agricultural production in county districts of Croatia, *Mathematical Communications, Supplement*, Vol. 1, No. 1, str. 111-119.

8. Balaguer-Coll, M.T., Narbón-Perpiñá, I., Peiró-Palomino, J., i Tortosa-Ausina, E. (2022) Quality of government and economic growth at the municipal level: Evidence from Spain. *Journal of Regional Science*, Vol. 62, str. 96–124. Dostupno na: <https://doi.org/10.1111/jors.12555> [6. ožujka 2024.]
9. Borge, L. E. i Naper, L. R. (2006) Efficiency Potential and Efficiency Variation in Norwegian Lower Secondary Schools, *FinanzArchiv Public Finance Analysis*, Vol. 62, No. 2, str. 221-249. Doi: 10.1628/001522106X120677.
10. Borge, L. E., Falch, T. i Tovmo, P. (2007) Public Sector Efficiency: The Roles of Political and Budgetary Institutions, Fiscal Capacity and Democratic Participation. *Norwegian University of Science and Technology*, Working Paper no. 8407.
11. Brennan, G. i Buchanan, J. (1980) *The Power to Tax: Analytical Foundations of a Fiscal Constitution*. Cambridge University Press: Cambridge.
12. Bucci, V., Ferrara, G. i Resce, G. (2024) Local government spending efficiency and fiscal decentralization: evidence from Italian municipalities, *Applied Economics*, Vol. 56, No. 5, str. 599-614, DOI: 10.1080/00036846.2023.2169241
13. Çağlar Onbaşıoğlu, D. (2021) The Turkish Cypriot Municipalities' Productivity and Performance: An Application of Data Envelopment Analysis and the Tobit Model, *Journal of Risk and Financial Management* Vol. 14, No. 9, str. 407. <https://doi.org/10.3390/jrfm14090407>
14. Charnes, A., Cooper W.W. i Rhodes, E. (1978) Measuring the efficiency of decision making units, *European Journal of Operational Research*, Vol. 2, No. 6, str. 429-444. Doi: 10.1016/0377-2217(78)90138-8
15. Cherchye, L. et al (2011) Constructing composite indicators with imprecise data: A proposal, *Expert Systems with Applications*, Vol. 38, No. 9, str. 10940-10949. Doi: 10.1016/j.eswa.2011.02.136
16. Cooper, W., Seiford, L. i Tone, K. (2000) *Data Envelopment Analysis, A Comprehensive Text with Models, Applications, References and DEA-Solver Software*. Kluwer Academic Publishers, Boston.
17. Čiković, K. F., Smoljić M. i Lozić J. (2021) The application of the non-parametric methodology DEA in the Croatian banking sector. *Economic and Social Development: Book of Proceedings*, Varazdin Development and Entrepreneurship Agency (VADEA).
18. Državni zavod za statistiku, *Statistika u nizu*, <https://podaci.dzs.hr/hr/statistika-u-nizu/>
19. Farrell, M. J. (1957) The measurement of productive efficiency, *Journal of the Royal Statistical Society*, Vol. 120, No. 3, str. 253-290. Doi: 10.2307/2343100
20. Giménez, V. i Prior, D. (2007) Long and Short Term Cost Efficiency Frontier Evaluation: Evidence from Spanish Local Governments, *Fiscal Studies*, Vol. 28, No. 1, str. 121-139.
21. Hunjet, D.; Neralić, L.; Wendell, R. E. (2014) Evaluation of the dynamic efficiency of Croatian towns using Data Envelopment Analysis, *Central European journal of operations research*, Vol. 23, NO. 3, str. 675-686. doi: 10.1007/s10100-014-0363-6

22. Jemrić, I. i Vujčić, B. (2002) Efficiency of banks in Croatia: a DEA approach, *Comparative Economic Studies*, Vol. 44, No. 2–3, str. 169–193.
23. Johnsson, M.C., Pepper, M., Price, O.M. i Richardson, L.P. (2021), «“Measuring up”: a systematic literature review of performance measurement in Australia and New Zealand local government», *Qualitative Research in Accounting & Management*, Vol. 18 No. 2, str. 195–227. Dostupno na: <https://doi.org/10.1108/QRAM-11-2020-0184> [6. ožujka 2024.]
24. Krüger, J. J., Cantner, U. i Hanusch, H. (2000) Total Factor Productivity, the East Asian Miracle, and the World Production Frontier, *Weltwirtschaftliches Archiv*, Vol. 136, No. 1, str. 111–136. Doi: 10.1007/BF02707398
25. Lo Storto, C. (2016) The trade-off between cost efficiency and public service quality: a non-parametric frontier analysis of Italian major municipalities. *Cities* 51, str. 52–63.
26. Rueda López, N.; Milán García, J., Uribe Toril, J. i de Pablo Valenciano, J. (2020) Evolution and latest trends of local government efficiency: Worldwide research (1928–2019), *Journal of Cleaner Production*, Vol. 261, str. 121276. Dostupno na: <https://doi.org/10.1016/j.jclepro.2020.121276>. [6. ožujka 2024.]
27. Marto M., Lourenço Marques J. i Madaleno M. (2022) An Evaluation of the Efficiency of Tertiary Education in the Explanation of the Performance of GDP per Capita Applying Data Envelopment Analysis (DEA), *Sustainability*, Vol. 14, No. 23, Doi: 10.3390/su142315524
28. Matić, R. (2023) *Fiskalna decentralizacija i utjecaj na ekonomski rast u odabranim zemljama Europske unije i Republici Hrvatskoj*. Doktorska disertacija. Ekonomski fakultet u Rijeci: Rijeka.
29. Mergoni, A. i De Witte, K. (2022) Policy evaluation and efficiency: a systematic literature review. *Intl. Trans. in Op. Res.*, Vol. 29, str. 1337–1359. Dostupno na: <https://doi.org/10.1111/itor.13012> [7. ožujka 2024.]
30. Milán-García, J., Rueda-López, N. i De Pablo-Valenciano, J. (2022), Local government efficiency: reviewing determinants and setting new trends. *Intl. Trans. in Op. Res.*, Vol. 29, str. 2871–2898. Dostupno na: <https://doi.org/10.1111/itor.13032> [6. ožujka 2024.]
31. Ministarstvo financija Republike Hrvatske, *Financijski izvještaji JLP(R)S*, <https://mf.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203>
32. Musgrave, R. A. (1959) *The Theory of Public Finance*. McGraw-Hill: New York.
33. Narbón-Perpiñá, I. i De Witte, K. (2018) Local governments' efficiency: a systematic literature review—part I, *International Transactions in Operational Research*, Vol. 25, str. 431–468. Doi: 10.1111/itor.12364
34. Neralić L., Gardijan Kedžo M. (2019) A Survey and Analysis of Scholarly Literature in DEA Published by Croatian Researchers: 1978 – 2018. *Zagreb International Review of Economics & Business*, 22(1), str. 93–106. <https://doi.org/10.2478/zireb-2019-0014>
35. Oates, W. E. (1972) *Fiscal Federalism*. Harcourt Brace Jovanovich: New York.
36. Pastor, J. M. et al (2018) Higher education institutions, economic growth and GDP per capita in European Union countries, *European Planning Studies*. Vol. 26, No. 8, str. 1616–1637.

37. Perugini, F. (2024) Local government efficiency and economic growth: The Italian case, *Socio-Economic Planning Sciences*, Vol. 91, 101775. Dostupno na: <https://doi.org/10.1016/j.seps.2023.101775> [6. ožujka 2024.]
38. Rabar, D. i Blažević, S. (2011) Ocjenjivanje efikasnosti hrvatskih županija u turizmu primjenom analize omeđivanja podataka, *Privredna kretanja i ekonomska politika*, Vol. 21, No. 127, str. 25–56.
39. Rabar, D. (2013) Assessment of regional efficiency in Croatia using dana envelopment analysis, *Croatian Operational Research Review*, Vol. 4, No. 1, str. 76–88. Dostupno na: <https://hrcak.srce.hr/97382> [9. ožujka 2024.]
40. Rabar, D. i Grbin, A. (2019) Analiza regionalne efikasnosti u Hrvatskoj korištenjem fiskalnih pokazatelja – neparametarski pristup, *Ekonomski pregled*, Vol. 70, No. 4, str. 627–649. Doi: 10.32910/ep.70.4.3
41. Rao, D. S. P. i Coelli, T. J. (1998) A Cross-country Analysis of GDP Growth Catch-up and Convergence in Productivity and Inequality, *Centre for Efficiency and Productivity Analysis (CEPA)*, Working Paper No. 5/98.
42. Scott, M. (1991) *A New View of Economic Growth: Four Lectures*, World Bank Discussion Papers No. 131, Washington DC: World Bank.
43. Slijepčević, S. (2009) *Mjerenje efikasnosti javne potrošnje u Hrvatskoj*. Doktorska disertacija. Zagreb: Sveučilište u Zagrebu, Ekonomski fakultet, Zagreb.
44. Stigler, G. (1957) The Tenable Range of Functions of Local Government, Federal Expenditure Policy for Economic Growth and Stability, *Washington DC: World Bank*, str. 213–219.
45. Šegota, A. (2008) Evaluating shops efficiency using data envelopment analysis: categorical approach, *Zbornik radova Ekonomskog fakulteta u Rijeci*, Vol. 26, No. 2, str. 325–343.
46. Škuflić, L., Rabar, D. i Škrinjarić, B. (2013) Assessment of the efficiency of Croatia compared to other European countries using data envelopment analysis with application of window analysis, *International Journal of Sustainable Economy*, Vol. 5, No. 1, str. 104–123.
47. Škuflić, L., Rabar, D. i Šokčević, S. (2010) Assesment of the efficiency of Croatian counties using Data Envelopment Analysis, *Economic Research*, Vol. 23, No. 2, str. 88–101. Doi: 10.1080/1331677X.2010.11517414
48. Šporčić, M., Martinić, I. i Šegotić, K. (2007). Ocjena efikasnosti radnih jedinica u šumarstvu analizom omeđivanja podataka, *Nova mehanizacija šumarstva*, Vol. 28, No. 1, str. 3–14. Dostupno na: <https://hrcak.srce.hr/21169> [7. ožujka 2024.]
49. Tran, CDTT. i Dollery, B. (2023) An empirical analysis of the impact of administrative intensity on the operational efficiency of the Victoria state local government system in Australia, *Local Government Studies*, Vol. 49, No. 3, str. 544–567, DOI: 10.1080/03003930.2021.2023015

ASSESSMENT OF THE EFFICIENCY OF PUBLIC EXPENDITURES IN CROATIAN COUNTIES USING DATA ENVELOPMENT ANALYSIS

Full Professor Alemka Šegota, PhD

University of Rijeka
Faculty of Economics and Business
e-mail: alemka.segota@efri.uniri.hr

Robert Matić, PhD

Maroni d.o.o.
e-mail: osiguranje@maroni.hr

Full Professor Helena Blažić Pečarić, PhD

University of Rijeka
Faculty of Economics and Business
e-mail: helena.blazic.pecaric@efri.uniri.hr

ABSTRACT

Unbalanced economic development in the Republic of Croatia is a complex problem that requires determining the optimal allocation and use of budgetary resources to achieve the highest possible economic growth. This paper identifies efficient and inefficient counties (including cities and municipalities within their territories) for the period 2017-2019. Data Envelopment Analysis (DEA) is applied to determine the optimal use of budgetary funds to achieve the highest possible economic growth at the regional level, i.e., across the entire Republic of Croatia. The counties identified as efficient throughout the period are Brod-Posavina County, Krapina-Zagorje County, Međimurje County, Varaždin County, and the City of Zagreb. Lika-Senj County consistently ranks last throughout the period. A slight increase in the average efficiency of Croatian counties was also noted. For the counties identified as inefficient, the causes and levels of inefficiency were determined. In order to facilitate the transition from inefficiency to efficiency, it is crucial to examine examples of good practice, i.e., to identify a reference county. Varaždin County serves as a reference for eight counties, including Lika-Senj, indicating that it is a potential model for achieving efficiency for these counties.

Key words: *efficiency, economic growth, regional self-government units, data envelopment analysis*

JEL classification: H72, 023, R11. C02, C61

USPOREDNA ANALIZA CARINSKOG I TROŠARINSKOG TRETMANA KAVE U EU-U I BIH

izv. prof. dr. sc. Lejla Lazović-Pita

Ekonomski fakultet, Sveučilište u Sarajevu

e-mail: lejla.lazovic@efsa.unsa.ba

Maida Tahirović, MA

I-Logistics d.o.o. Sarajevo

e-mail: maida.tahirovic@gmail.com

SAŽETAK

Carinski i trošarinski tretman kave tema je kojoj se posvećuje malo pozornosti u teorijskim i praktičnim akademskim istraživanjima. Dakle, cilj ovog rada jest praktična usporedba carina i trošarina na kavu u Bosni i Hercegovini (BiH) i SR Njemačkoj kao primjeru članice Europske unije (EU) koja je najveći uvoznik kave u EU-u. Analiza se sprovodi odvojeno za dva scenarija: uvoza kave s i bez preferencijalnog podrijetla. Rezultati provedene usporedne analize ukazuju na to da ne postoje razlike u nomenklaturi carinskog harmoniziranog sustava (HS) kave u SR Njemačkoj i BiH, što usporedivost čini jednostavnom. Rezultati također ukazuju na razlike u ukupnom iznosu plaćenih davanja na kavu u BiH i SR Njemačkoj ovisno o postojanju carinskog preferencijalnog podrijetla, kao i specifičnostima trošarinskog tretmana kave.

Ključne riječi: kava, carina, trošarina, Bosna i Hercegovina, Europska unija

JEL klasifikacija: H2

1. UVOD

Kako bismo adekvatno pristupili analizi carinskog i trošarinskog tretmana kave u BiH i EU-u, prvo pitanje koje se postavlja vezano je uz izbor kave koju je zakonodavac u BiH i određenim članicama EU-a svrstao u grupu proizvoda koji su predmetom oporezivanja trošarinama. Kava je zimzelena tropska biljka čiji plodovi u obliku zrna kave sadrže kofein. Kofein je alkaloid koji se uglavnom

nalazi u zrnu kave, lišću čaja i zrnu kakaa, te kao kemijski spoj ima specifično djelovanje na ljudski organizam. Primjerice, nikotin sadržan u duhanu zajedno s drugim opijatima pripadaju skupini alkaloida. S obzirom na to da zrna kave, a onda i proizvodi od kave imaju različit sadržaj kofeina, koliko će kofeina sadržavati kava, ovisi o više čimbenika (npr. proces uzgajanja kave, temperatura prženja, koliko je kava sitno mljevena i dr.).

Na svjetskoj razini, oko 25 milijuna ljudi uzgaja kavu, za oko 125 milijuna širom svijeta kava je ekonomska osnova za život, te se oko 80 % kave proizvede u malim obiteljskim gospodarstvima (Rotta *et al.*, 2021; Fairtrade foundation, 2023). Međutim, dodana vrijednost sadržana u kavi nije ravnomjerno raspoređena kroz lanac opskrbe kavom. Općenito, većina kave izvozi se kao sirova kava iz zemalja uzgajivača kave, a dodana vrijednost u smislu prženja i prerade događa se u zemljama uvoznicama (Europa i SAD).

Iako postoji preko 100 vrsta kave, najpoznatije i ekonomski najvažnije dvije vrste kave na svijetu su Arabica i Robusta (Rotta *et al.*, 2021), čije se cijene određuju na robnom tržištu. Zrna Arabice sadrže gotovo upola manje kofeina nego Robuste, tako da Arabica ima prosječno 1,2 % kofeina, dok Robusta ima 2,2 % (Preuss, 2022). Promatrajući trogodišnje kretanje cijena kave Arabica i Robusta, koje su uslijed pada potražnje izazvane pandemijom bolesti COVID-19 bile znatno niže nego prethodnih godina, u razdoblju 2020. – 2022., prema podacima Svjetske banke, cijena sorte Arabica rasla je s 3,32 \$/kg u 2020. na 5,63 \$/kg u 2022. godini, a cijena sorte Robusta s 1,52 \$/kg u 2020. na 2,29 \$/kg u 2022. godini (Svjetska banka, 2023).

Carine i trošarine predstavljaju vrste javnih prihoda koje države određuju na temelju svog fiskalnog suvereniteta. Carina je vrsta javnog prihoda koji se plaća na robu koja prelazi državnu, odnosno carinsku granicu (Hrvatska enciklopedija, 2021). Po osnovnim karakteristikama svrstava se u skupinu neizravnih poreza, naplaćuje se na potrošnju, uključuje se u cijenu robe i prenosi na krajnjeg potrošača. S obzirom na prirodu davanja kojoj pripadaju i carine i porezi, i carine imaju sljedeće elemente: carinski vjerovnik, carinski dužnik, carinska osnovica, carinska stopa, carinska olakšica. Obveza plaćanja carine kao protekcionističke mjere nastaje ulaskom predmetne robe na carinsko područje. Za države članice EU-a, carinski postupci u velikoj su mjeri određeni pravom EU-a, popraćeno nacionalnim zakonodavstvom, tj. europska pravila vrijede u svakoj zemlji. Slijedom toga, za zemlje koje postaju nove članice EU-a, carinska politika zahtijeva prilagođavanje, kao što su određene stavke u carinskim

olakšicama i režimima, prihvaćanje tranzitnog sustava EU-a, odnosno kretanje robe preko teritorija druge države članice EU-a bez carinskih barijera.

Trošarina je poseban porez na promet visokotarifnih dobara, obračunava se i plaća u apsolutnom iznosu po jedinici mjere i/ili po proporcionalnoj stopi (Zakon o akcizama u Bosni i Hercegovini, 2022, članak 16.). Uglavnom se primjenjuje radi ispunjavanja fiskalnih i nefiskalnih/izvanfiskalnih ciljeva u oporezivanju. Fiskalni ciljevi odnose se na prihodovnu funkciju države, a nefiskalni ciljevi uglavnom su socijalni, zdravstveni, ekološki, gospodarski i drugi ciljevi. Važeće europsko zakonodavstvo (Europska unija, 2022a) vezano uz trošarine propisuje trošarinske obveze na sljedeću robu:

- energente i električnu energiju, Direktiva 2003/96/EZ
- alkohol i alkoholna pića, Direktive 92/83/EEC i 92/84/EEC
- prerađeni duhan, Direktiva 2011/64/EU.

Ova odredba dopušta državama članicama Europske unije da prikupljaju neizravne poreze za posebne svrhe na robu podložnu trošarinama, uz uvjet poštovanja pravila EU-a i poreza na proizvode.

Uzimajući u obzir kompleksnost carinskih i poreznih procedura, cilj ovog rada jest po prvi put dati teorijski i praktični usporedni prikaz carinskog i trošarinskog tretmana kave u BiH kao zemlji izvan EU-a i u članicama EU-a. S tim u vezi, u radu se definira sljedeće istraživačko pitanje:

U kojoj su mjeri usklađene carinska i trošarinska politika u području oporezivanja kave u BiH i u EU-u u slučajevima uvoza kave s i bez preferencijalnog podrijetla?

Rad je organiziran na sljedeći način: nakon uvoda dajemo kratak pregled literature. Poseban fokus u radu dan je na razumijevanju praktične dimenzije carinske i trošarinske procedure pri tretmanu kave koja će biti predstavljena u poglavlju usporedne analize. Na kraju rada dajemo zaključak, ograničenja istraživanja, kao i preporuke za daljnja istraživanja na ovu temu.

2. PREGLED LITERATURE

Ekonomska i financijska literatura koja tretira problematiku kave, posebno njezinu carinsku i trošarinsku komponentu, gotovo je nepostojeća. Naime, pregledom dviju najvećih znanstvenih baza podataka Web of Science i Scopus

po ključnim riječima – *coffee*, *excise* i *customs*¹, u svim poljima ili uopće ne generiraju rezultate (engl. Web of Science) ili generiraju svega jedan rezultat u slučaju baze podataka Scopus (rad se bavi predviđanjem izvoza kave u Indoneziji, Nasution *et al.*, 2018), te nije relevantan za ovu temu. Sužavanjem polja pretraživanja na isključivo dva pojma u svim poljima – *coffee* i *excise* dobiva se svega sedam rezultata (Scopus), odnosno 27 (Web of Science). Međutim, većina radova dolazi iz medicinskih ili biomedicinskih znanosti, te postoje svega dva znanstvena rada iz obiju baza koji se bave problematikom trošarinskog tretmana kave, čije rezultate dajemo u nastavku.

Od 1993. godine, kada se njemački sustav trošarina prilagođavao EU standardima slobodne trgovine, neke „manje“ trošarine su ukinute (npr. trošarine na čaj, žarulje, šećer i sol), ali je trošarina na kavu ostala. Njemačka industrija kave podržala je zadržavanje trošarine na kavu, te je Feuerstein (1996; 2002) želio istražiti teorijske i empirijske razloge zbog kojih njemačka industrija kave preferira visoke cijene svog glavnog *inputa* – zelene kave. Teorijski razlozi objašnjeni su činjenicom da se kava smatra homogenim proizvodom, a pretpostavlja se da je tržište klasificirano kao oligopol, gdje povećanje marginalnih troškova zbog trošarine na kavu utječe na dobavljače da smanje količinu i povećaju cijenu proizvoda. Ovo, konačno, može imati pozitivan učinak na njihove prihode, jer rast dobiti premašuje trošak trošarine s kojim se poduzeće suočava (Feuerstein, 1996). U empirijskoj analizi odnos cijena i troškova pečenja kave u SR Njemačkoj procjenjuje se s pomoću modela korekcije pogreške (engl. *error correction model*). Rezultati pokazuju da troškovni šokovi dovode do promjena cijena u približno istom iznosu ostavljajući, marginalno gledajući, nepromjenjive odnose cijene – troška. Feuerstein (2002) u ekonometrijskoj analizi pokazuje da se promjene troškova u potpunosti prenose na cijene, te da percepcija njemačke industrije kave da visoki troškovi impliciraju visoku dobit nije točna. Međutim, drugi dugoročni faktori također su značajni, kao što je, primjerice, činjenica da niske cijene kave na svjetskom tržištu mogu imati negativan učinak na dugoročne ponude zelene kave, što rezultira budućim nestajcima i skokovima cijena, da silazni trend cijena može odražavati pojačanu konkurenciju između pržionica kave koja se može objasniti promjenom odnosa prema kavi od strane kupaca itd.

Dodatno, u znanstvenoj bazi Web of Science, pretraživanjem još dvaju pojmova – *coffee* i *tax* prema predmetu istraživanja u ekonomskoj znanosti, dolazimo

¹ Pretrage su izvršene na bazi navedenih triju ključnih riječi u opcijama *all fields* i *topic* zajedno s opcijom *and*.

do 23 rezultata. Međutim, pojmovno proširivanje rezultira time da se u većini znanstvenih radova kava i porezna davanja analiziraju s ostalim zaslađenim pićima i njihovom cjenovnom elastičnosti (engl. *sugar-sweetened beverages*, npr. Jones-Smith *et al.*, 2020), a time i zdravstvenim implikacijama takvih studija (npr. Dharmasena i Capps, 2012). Kave je analizirana i s ostalim pićima (npr. mlijekom ili jogurtom kao osnovnim životnim namirnicama u njihovu PDV tretmanu u npr. Lyssiotou i Savva, 2021), ili su mjerene tržišne distorzije, globalni lanci opskrbe ili porezne implikacije za slučajeve zemalja izvoznica kave (Brazil i druge zemlje izvoznice kave, npr. Lima i Lee, 2023, za mogućnost uvođenja poreza na izvoz kave).

Osim navedenoga, prethodni znanstveni i praktični pravci istraživanja kave bili su usmjereni na determinante potražnje za kavom, cijenu kave i njezinih nadomjestaka (čaj), dohodak potrošača, razvoj stanovništva i tržišta, cjenovnu elastičnost i promjene preferencija potrošača (Kutty, 2000). Postoje teorije koje sugeriraju da bi sniženje cijene sirovine (zelene kave) za krajnjeg kupca moglo rezultirati značajnim povećanjem izvoza sirove kave. Međutim, autori (Durevall, 2007) navode da, u dugom roku, smanjenje cijene kave na tržištu vjerojatno ne bi imalo značajan utjecaj na potražnju za kavom zbog čimbenika koji su povezani sa samim potrošačima te demografskim promjenama i različitim preferencijama prema dobi (Durevall, 2007).

Pod utjecajem globalizacije, u posljednjem desetljeću bilježi se porast ukupne potrošnje kave kako na svjetskoj razini tako i u BiH. U BiH, kava je došla u fazu da od tradicionalnog pića prerasta u piće koje je u skladu sa svjetskim trendovima i preferencijama zapadnih potrošača, čime u BiH kava ima i kulturnu važnost koja utječe na potražnju za kavom u zemlji, a time i prihodovnu dimenziju trošarina na kavu (Odjel za makroekonomsku analizu UINO-a, 2021, str. 14 – 20). Potražnja za instant-kavom ili mješavinama espresso kave raste, dok uspostavljena tradicija bosanske kave nastavlja podržavati prodaju svježe mljevene kave u zemlji. Izvanredne okolnosti, poput pojave pandemije bolesti COVID-19 2020. godine, mjere izolacije i socijalnog distanciranja utjecale su na konzumaciju kave. Zabrana okupljanja i druge mjere uvedene protiv širenja virusa preorijentirale su potrošače na konzumaciju kave kod kuće, odnosno na konzumaciju bosanske kave, instant-kave, kave u „kapsulama“ iz kućnih aparata za kavu i slično, dok je smanjena konzumacija espresso kave najviše u barovima i restoranima (Odjel za makroekonomsku analizu UINO-a, 2021, str. 14 – 20).

3. OSNOVNE NAZNAKE O CARINSKOM TRETMANU ROBA U EU-U I BIH

Današnji EU prošao je dug vremenski i institucionalni proces ujedinjenja carinske politike, odnosno proces koji, *inter alia*, harmonizira stope carine na robe koje se uvoze u EU. Današnji EU funkcionira kao carinska unija formirajući jedno unificirano carinsko tijelo koje se sastoji od carinskih institucija članica EU-a. Dakle, carina se ne naplaćuju pri prijevozu robe unutar zemalja članica EU-a, a ukupni carinski prihodi na uvezenu robu u EU čini oko 14 % proračuna EU-a (Europska unija, 2022b; Europska komisija, 2022a). Osim prihodovne dimenzije, na vanjskim granicama EU-a, carinska unija i radi provjere roba i proizvoda kako ne bi bili opasni ili štetni po zdravlje građana EU-a, kao i na sprečavanju carinskih i trošarinskih prevara (Europska unija, 2022b).

U 2021. godini u smislu strukture uvoza u EU, najveći udio uvoza bio je predmetom nulte stope carine (70 %, Eurostat, 2022a). Kada se roba iz ostatka svijeta uvozi na područje EU-a, na nju se primjenjuju iste carinske stope, ali se prilikom razmjene unutar EU-a na takvu robu dalje ne obračunava carina. Hoće li roba koja se uvozi biti tretirana nultom ili nekom višom carinskom stopom ovisi, *inter alia*, o statusu robe, odnosno je li s ili bez preferencijalnog podrijetla. Takav status ovisi o pravnom sporazumu, odnosno o tome je li EU potpisao i ratificirao vanjskotrgovinski sporazum kojim se tretira problematika preferencijalnog podrijetla između zemalja ugovornica, a koje posljedično utječu na zakone i pravila koja se reguliraju carinske stope. Dakle, (supranacionalna) europska carinska pravila primjenjuju se jednako u svakoj zemlji članici EU-a, odnosno carinske procedure određene su pravilima EU-a zajedno s nacionalnom legislativom. Kada zemlje pristupaju EU-u, one prilagođavaju svoje nacionalno zakonodavstvo prema pravilima EU-a. To se posebno odnosi na carinske olakšice i posebne carinske režime, tranzitni sustav zajednice koji upravo omogućava kretanje roba kroz teritorije zemalja članica EU-a, ali bez carinskih prepreka.

Od 1988. godine na svjetskoj razini usvojen je i prihvaćen unificirani Sustav deskripcije i evidentiranja roba pod nazivom Harmonizirani sustav opisa i kodiranja robe (engl. *Harmonized Commodity Description and Coding System*, HS). HS nomenklatura omogućava preciznu identifikaciju proizvoda i provjeru tarifnih stopa i pravila koji se primjenjuju. HS je logična struktura za klasifikaciju robe, kojom se uniformno koriste carinski organi širom svijeta (Europska komisija, 2022c). S obzirom na to da su HS kodovi univerzalni, oni prevladavaju eventualne jezičke i druge barijere omogućavajući sudionicima u carinskoj proceduri efikasnu i lakšu identifikaciju robe. Kako se roba kategorizira, odnosno

označava tarifnim oznakama, time se olakšava cjelokupni proces utvrđivanja odgovarajućih tarifnih stopa, a koje se koriste za utvrđivanje davanja, kao što su uvozna/izvozna carina, trošarina i porez na dodanu vrijednost (PDV). Bez obzira na vrijednost robe, Svjetska carinska organizacija (engl. *World Customs Organization* – WCO) razvila je HS nomenklaturu koja prema HS robnom sustavu utvrđuje stopu carine prema klasi robe (WCO, 2022).

HS hijerarhijsku nomenklaturu čini nekoliko segmenata: *Odsjek*, *Poglavlje* (2 cifre), *Tarifni broj* (4 cifre) i *Tarifni podbroj* (6 cifara).

U EU-u primjenjuje se kombinirana nomenklatura u oznaci „KN“, koja ima 8 cifara te je, u smislu HS nomenklature, oznaka EU-a vidljiva u sedmoj i osmoj cifri. Sedma i osma cifra označene su kao „00“ u situaciji da se oznaka dalje ne dijeli. U slučaju BiH, nomenklature BiH imaju 10 cifara, odnosno sadrže osmeroznamenastu KN nomenklaturu zajedno s devetom i desetom cifrom za potrebe BiH. S obzirom na to da je BiH pristupila Međunarodnoj konvenciji o Harmoniziranom sustavu nazivlja i brojčanog označavanja robe, time se obvezala na korištenje svih tarifnih brojeva i podbrojeva, kao i općih pravila od 1. do 6. o razvrstavanju roba, uz sve napomene uz odjeljke, poglavlja i podbrojeve (Ministarstvo vanjske trgovine i ekonomskih odnosa Bosne i Hercegovine, 2016, str. 7). U smislu carinskog tretmana kave, HS oznake za sirovu, prženu i druge vrste kave jednake su u EU-u i BiH.

HS kodiranje, odnosno tarifiranje koriste sve zainteresirane strane u carinskoj i izvancarinskoj proceduri, i to za razne potrebe (porezne, statističke, kontrolne i dr.). S tim u vezi, Mohamed (2016) naglašava značaj tehničkog znanja za točnu primjenu HS sustava i klasifikacije od strane sudionika u carinskoj proceduri.

S obzirom na to da su carine javni prihod, značaj ispravnog klasificiranja roba od velikog je značaja, te svaka neispravna klasifikacija (uključujući i namjerna) u pogrešnu tarifnu kategoriju može se smatrati poreznom evazijom. Međutim, s obzirom na kompleksnost cijelog procesa i činjenice da određene robe mogu biti klasificirane u više tarifnih kategorija, u BiH i širom svijeta postoje pravilnici i tzv. komentari na carinsku tarifu koji pomažu u navedenoj kategorizaciji.

U carinskom smislu, roba može biti s preferencijalnim i bez preferencijalnog podrijetla. Roba s preferencijalnim podrijetlom ovisi o potpisanim i ratificiranim međunarodnim sporazumima između dviju zemalja koje posljedično daju povoljniji carinski tretman pri uvozu robe, čime direktno utječu na potražnju za navedenom robom. Preferencijalno podrijetlo stječe se sukladno pravilima države koja proizvodi/otprema robu iz navedene zemlje. Za slučaj trgovinskih

pravila o preferencijalnom tretmanu između BiH i EU-a, u 2008. godine potpisan je Privremeni sporazum o trgovini i trgovinskim pitanjima između Europske zajednice, s jedne strane, i Bosne i Hercegovine, s druge strane (engl. *Interim agreement on trade and trade-related matters between the European Community, of the one part, and Bosnia and Herzegovina, of the other part*, Eur-Lex, 2008).

Osim preferencijalnih stopa, na osnovu Generaliziranog sustava preferencija (engl. *Generalised scheme of preferences* – GSP, UNCTAD Konferencija Ujedinjenih naroda o trgovini i razvoju iz 1968. godine), u carinskoj proceduri postoje i povlaštene carinske stope. Osmišljene u korist zemalja u razvoju, a bez reciprociteta ili diskriminacije, ove posebne mjere žele povećati izvoz i izvozne prihode, promovirati industrijalizaciju i povećati stope ekonomskog rasta najnerazvijenijim zemljama u svijetu (Ministarstvo vanjske trgovine i ekonomskih odnosa Bosne i Hercegovine, 2018).

GSP EU-a sastoji se od tri aranžmana:

1. Za zemlje niskog i srednjeg prihoda, primjenjuje se standardni GSP koji podrazumijeva djelomično ili potpuno ukidanje carina na dvije trećine tarifnih stavki.
2. Za ugrožene zemlje niskog i nižeg srednjeg prihoda primjenjuje se GSP+ sa smanjenim tarifama na 0 % kao poseban poticajni aranžman za održivi razvoj i dobro upravljanje.
3. Za najmanje razvijene zemlje primjenjuje se aranžman *Everything But Arms* (EBA), koji omogućava pristup tržištu EU-a bez carina i kvota za sve proizvode, osim oružja i municije (Europska komisija GSP, n.d.).

4. USPOREDNA ANALIZA CARINSKOG TRETMANA KAVE U EU-U I BIH

S obzirom na to da su carinske stope unutar članica EU-a harmonizirane, isto vrijedi i za tarifne oznake za potkategorije kave. U Tablici 1. daje se usporedna analiza carinskog tretmana uvoza različitih kategorija kave u SR Njemačku kao predstavnicu članica EU-a, i to za situaciju uvoza kave iz zemlje preferencijalnog podrijetla (Švicarska) i bez preferencijalnog podrijetla (Brazil). SR Njemačka jedna od najvećih uvoznica kave u EU te svake godine uveze kave u vrijednosti od oko 500 milijardi eura (EUR, Federal Ministry for Economic Cooperation and Development, 2021). Ako analiziramo kategorije kave koje su

tretirane trošarinama jednako u EU-u i BiH za razdoblje 2017. – 2021., vrijednost uvoza u EU doseže čak do 1,97 milijardi EUR² godišnje.

Iz Tablice 1. vidljive su carinske implikacije pri uvozu kave iz zemlje s preferencijalnim podrijetlom (Švicarske) i zemlje bez preferencijalnog podrijetla (Brazil, Warenursprung und Präferenzenonline, n. d.). Iako je još 2000. godine EU započeo pregovore s Brazilom³ o Sporazumu o slobodnoj trgovini za različite robe osim kave, te iako je sporazum postignut u 2019. godini, on još uvijek nije ratificiran (Europska komisija, *EU trade relations with Brazil*, n.d.; Da Silva, 2023). Carinske stope međusobno se dogovaraju između EU-a i drugih država ili carinskih unija, što znači da se u implementiranim sporazumima može primjenjivati carinska stopa od 0 % ili, jednostavno, niža carinska stopa u odnosu na standardnu, čime se carinska procedura i cjelokupan sustav dodatno komplicira i stvara dodatne distorzije na tržištu. Kako je vidljivo iz Tablice 1., za uvezene subkategorije kave iz Brazila kao zemlje bez preferencijalnog podrijetla, standardna carinska stopa na uvoz pržene kave jest 7,5 %, na prženu kavu bez kofeina 9 %, a na supstitute od kave 11,5 % (*Centre for the Promotion of Imports from developing countries*, 2022). S obzirom na to da je tržište kave, u pravilu, cjenovno neelastično i razvijeno, carinska i druga davanja ne utječu na potrošnju kave u zemljama uvoznicama kakva je SR Njemačka (Međunarodna organizacija za kavu (engl. *International Coffee Organisation*), 2011).

U BiH, carinske stope na kavu drugačije su nego u SR Njemačkoj, što je vidljivo iz Tablice 1., ali je procedura obračuna na kavu i potkategorije kave jednaka (carina, trošarina i PDV). Tako su u BiH u primjeni tri carinske stope na kavu i potkategorije kave: 0 %, 5 % i 10 % (ako sporazumima o slobodnoj trgovini nije definirano preferencijalno podrijetlo). U Tablici 1. vidljivo je da su sirova kava s i bez kofeina, njezine potkategorije, te zamjena za kavu, npr. cikorija, predmetom carine od 5 %, pržena kava s i bez kofeina predmetom carinske stope od 10 %, a na kavine ljuske i opne primjenjuje se 0 % (Tablica 1., Zakon o carinskoj tarifi, 2012, i Ministarstvo vanjske trgovine i ekonomskih odnosa Bosne i Hercegovine, n. d., str. 96 – 164).

Prema dostupnim podacima, BiH ima trgovinske sporazume o slobodnoj trgovini s članicama EU-a, CEFTA-e, EFTA-e, te Turskom i Iranom (UINO, Spo-

² Kalkulacija autora na temelju podataka Europske komisije iz 2022. godine o statističkoj vrijednosti prilikom uvoza u razdoblju 2017. – 2021.

³ Dio pregovora EU-a o Sporazumu o pridruživanju sa zemljama Mercosura, koje uključuju Brazil, Argentinu, Urugvaj i Paragvaj.

razumi o slobodnoj trgovini, n. d.). Za sve navedene sporazume primjenjuje se carinska stopa od 0 % po osnovi preferencijalnog podrijetla, osim s Islamskom Republikom Iran, za koju sporazum o preferencijalnoj trgovini nije ratificiran, pa se na uvoz kave primjenjuju stope od 5 % i 10 %.

Pregled carinskih tarifnih oznaka za proizvode od kave koje su predmetom trošarine u BiH dan je u Tablici 1. Sukladno objašnjenju, ovisno o tarifnoj oznaci kave, zemlje (preferencijalnog) podrijetla primjenjuju i različite carinske stope (Ministarstvo vanjske trgovine i ekonomskih odnosa Bosne i Hercegovine, n. d., str. 96 – 164). Stopa PDV-a koja se primjenjuje na kavu u BiH jest standardna stopa i iznosi 17 % (Zakon o porezu na dodatnu vrijednost Bosne i Hercegovine, 2017).

Tablica 1. Pregled carinskih stopa na kavu u Europskoj uniji (uvoz u SR Njemačku)

HS oznaka	CT u BiH % za robe bez pref. podrijetla	CT u BiH % za robe s pref. podrijetlom	CT u EU-u % za uvoz roba bez sporazuma o pref. podrijetlu (Drittlandszollsat)	CT u EU-u % prilikom uvoza za robe s pref. podrijetlom
0901 11 00 00 – sirova kava s kofeinom	5	0	0	0
0901 12 00 00 – sirova kava bez kofeina	5	0	8,3	0
0901 21 00 00 – pržena kava s kofeinom	10	0	7,5	0
0901 22 00 00 – pržena kava bez kofeina	10	0	9	0
0901 90 10 00 – kavine ljuske i opne	0	0	0	0
0901 90 90 00 – nadomjesci kave što sadrže kavu	5	0	11,5	0
2101 11 00 00 – ekstrakti, esencije i koncentrati od kave	5	0	9	0
2101 12 92 00 – pripravci na osnovi ekstrakata, esencija ili koncentrata od kave	5	0	11,5	0
2101 12 98 00 – ostali proizvodi	5	0	9	0

Izvor: Generalzolldirektion, 2023, i Ministarstvo vanjske trgovine i ekonomskih odnosa Bosne i Hercegovine, n. d., str. 96 – 164

Podaci iz Tablice 1. ukazuju na mogućnost uvoza sirove kave bez kofeina u EU po stopi od 0 %, dajući mogućnost na tržištu EU-a da se takva kava preradi te doda vrijednost, a uzimajući u obzir da je pržena kava bez kofeina predmetom carinske stope od 9 %. Sličan zaključak može se izvući i usporedbom carinskih stopa na sirovu kavu i neprerađene proizvode za razliku od gotovih proizvoda od kave. U ovom procesu, zemlje uvoznice kave štite domaću industriju višim carinskim stopama na gotove proizvode u odnosu na niže carinske stope za poluproizvode i/ili sirovine, što se još naziva i „tarifna eskalacija“ (engl. *Tariff escalation*). Sasvim je jasno da se ovakvom praksom dalje održava postojeća situacija uvoza sirovine – sirove kave, gdje je mala dodana vrijednost u odnosu na njezinu preradu u zemljama uvoznicama kakav je EU, koji ima veće prerađivačke kapacitete nego zemlje izvoznice kave.

Uspoređujući rezultate u Tablici 1., možemo vidjeti da se u EU-u sirova kava s kofeinom ne tretira carinom bez obzira na to je li riječ o uvozu kave s ili bez preferencijalnog podrijetla. U BiH, sirova kava s kofeinom bez preferencijalnog podrijetla jest predmet carinske stope od 5 %, te je uvoz sirove kave s kofeinom u BiH za robe s preferencijalnim podrijetlom iz EU-a, CEFTA-e, EFTA-e te Turske predmet nulte carinske stope. Značajne razlike u stopama postoje i u ostalim kategorijama kave, kako je prikazano u Tablici 1.

5. USPOREDNA ANALIZA CARINSKOG I TROŠARINSKOG TRETMANA KAVE U EU-U I BIH

Već smo naveli tri skupine roba koje trenutačno europsko zakonodavstvo tretira trošarinama, te utvrdili da kava nije ni u jednoj od triju definiranih skupina. Većina članica EU-a nije uvela trošarine na kavu, a stope PDV-a na kavu u EU-u su šarolike, a u primjeni su i standardne i snižene stope PDV-a u ovisnosti o vrsti koja se uvozi (Međunarodna organizacija za kavu, 2011).

Svega šest zemalja članica EU-a primjenjuju trošarine na kavu koja se obračunava kao poseban neizravni porez, a to su: Belgija, Hrvatska, Danska, Grčka, Latvija i SR Njemačka (Europska komisija, 2022b). Prikaz iznosa trošarina za navedenih šest članica EU-a i BiH koje oporezuju kavu dan je u Prilogu 1. Udio prihoda od trošarina za kavu u ukupnim prihodima od trošarina u svakoj članici EU-a u razdoblju 2017. – 2022. vrlo je mali i u prosjeku se kreće od 0,7 % u Hrvatskoj i Danskoj do 1,9 % u Grčkoj (Eurostat, 2022b). U BiH u razdoblju 2017. – 2022. godišnji prihod od trošarina na kavu u prosjeku je iznosio 40

milijuna konvertibilnih maraka (KM) ili 2,9 % ukupnih prihoda od trošarina, odnosno u prosjeku je uvezeno 21 milijun tona godišnje.

U ovom radu dajemo primjer carinskog i trošarinskog tretmana kave za članicu EU-a, odnosno najvećeg uvoznika kave u EU-u, SR Njemačku, koju uspoređujemo s BiH kao zemljom koja nije članica EU-a. Jednadžba za obračun carinskih i trošarinskih davanja u BiH i SR Njemačkoj je ekvivalentna. Ako se radi o paritetu *ex works* (EXW⁴), što u praksi znači da uvoznik snosi sve troškove vezane za špediciju, transport i carinske formalnosti, primjenjuje se obračun u nastavku:

$$\text{carinska osnovica} = \text{vrijednost robe} + \text{vanjski troškovi}$$

$$\text{trošarinska osnovica} = \text{stopa} * \text{kg neto}$$

$$\text{PDV osnovica} = \text{carinska osnovica} + \text{trošarina} + \text{unutrašnji troškovi}$$

Carinska nomenklatura, odnosno tarifne oznake (HS oznake) koje se koriste u primjerima u nastavku jednake su za BiH i za EU: pržena kava s kofeinom (HS 9012 10 00) i pržena kava bez kofeina (HS 9012 10 00).

U Tablici 2. nalazi se usporedni obračun carinskih davanja prilikom uvoza kave u BiH i SR Njemačkoj za kavu s preferencijalnim podrijetlom iz Švicarske, na paritetu EXW. Pretpostavka je da se pošiljka sastoji od dvaju navedenih artikala – pržene kave s kofeinom (HS 9012 10 00) i pržene kave bez kofeina (HS 9012 10 00). Prema tarifnoj oznaci pošiljke za obje vrste kave, u BiH se obračunava trošarina od 3 KM/kg, a u SR Njemačkoj trošarina od 2,19 EUR/kg.

⁴ Paritet/Incoterm: *Ex Works* – podrazumijeva da svi troškovi, uključujući davanja i transport, padaju na teret uvoznika.

Tablica 2. Usporedni obračun carinskih i trošarinskih davanja prilikom uvoza kave u BiH i u SR Njemačku za pošiljku s preferencijalnim podrijetlom

Tarifna oznaka		0901 21 00	0901 22 00
Opis tarifne oznake		Pržena kava s kofeinom	Pržena kava bez kofeina
1.	Neto masa u kg	10.578	288
2.	Vrijednost robe u KM	159.812,10	5.976,35
3.1.	Vanjski troškovi (do granice)	649,34	13,69
3.2.	Unutrašnji troškovi (od granice)	649,34	13,69
4.1.	Carinska osnovica (2. + 3.)	160.461,44	5.990,04
4.2.	Carina 0 %	0	0
BA	5.	Trošarina – stopa 3 KM/kg	31.734,00
	6.1.	PDV osnovica	192.844,80
		(3.2. + 4.1. + 5.)	6.867,73
	6.2.	PDV 17 %	32.783,61
	7.	Ukupna davanja po tarif. oznaci	64.517,61
		Ukupna davanja po carinskoj deklaraciji	2.031,51
DE	5.	Trošarine – stopa 4,28 KM/kg	66.549,13 KM
	6.1.	PDV osnovica	45.273,84
		(3.2. + 4.1. + 5.)	1.232,64
	6.2.	PDV 7 %	206.384,62
	7.	Ukupna davanja po tarif. oznaci	7.236,37
		Ukupna davanja po carinskoj deklaraciji	14.446,92
			506,55
			1.739,19
			61.459,95 KM

Izvor: vlastiti obračun davanja s pomoću carinskog softvera *Asycuda*

Iz Tablice 2. vidljivo je da se ukupna davanja koja uvoznici u BiH i u SR Njemačkoj snose, na ovom primjeru, sastoje iz troškova transporta, trošarine i PDV-a. Prilikom usporedbe davanja koja se obračunavaju na prženu kavu, s i bez kofeina, u objema zemljama, a koristeći se istim relevantnim parametrima za obračun (težinu, vrijednost robe i trošak transporta), evidentno je da su trošarine u BiH na prženu kavu manje u odnosu na trošarine u SR Njemačkoj zato što je trošarina na kavu u BiH manja za 1,28 KM po neto kg u odnosu na njemačku stopu za isti proizvod.

U ovom primjeru, stopa carine na prženu kavu, neovisno je li s ili bez kofeina je 0 %, kako u BiH tako i u SR Njemačkoj. Kako smo prethodno vidjeli, nulta stopa carine u praksi se primjenjuje ako se radi u uvozu u EU za pošiljke s preferencijalnim podrijetlom kakva je Švicarska (Warenursprung und Präferenzonline, n. d.). U konačnici, trošak po carinskoj deklaraciji veći je za uvoznika

u BiH u odnosu na uvoznika u SR Njemačkoj, i to zbog stope PDV-a na kavu, koja je u BiH 17 %, a u SR Njemačkoj 7 %.

Slično primjeru iz Tablice 2., u Tablici 3. dajemo usporednu analizu uvoza kave u BiH i SR Njemačku iz zemlje bez preferencijalnog podrijetla – Brazila pod istim pretpostavkama kao i u Tablici 2. (pošiljka koja se sastoji od pržene kave s kofeinom (HS 9012 10 00) i pržene kave bez kofeina (HS 9012 10 00 na paritetu EXW).

Tablica 3. Usporedni obračun carinskih i trošarinskih davanja prilikom uvoza kave u BiH i u SR Njemačku za pošiljku bez preferencijalnog podrijetla

Tarifna oznaka		0901 21 00	0901 22 00
Opis tarifne oznake		Pržena kava s kofeinom	Pržena kava bez kofeina
1.	Neto masa u kg	10.578	288
2.	Vrijednost robe u KM	159.812,10	5.976,35
3.1.	Vanjski troškovi (do granice)	649,34	13,69
3.2.	Unutrašnji troškovi (od granice)	649,34	13,69
4.1.	Carinska osnovica (2. + 3.1.)	160.461,44	5.990,04
	4.2. Carinska stopa	10 %	10 %
	4.3. Iznos carine	16.046,14	599,00
BA	5. Trošarina – stopa 3 KM/kg	31.734,00	864,00
	6.1. PDV osnovica (3.2. + 4.1. + 4.3. + 5.)	208.890,92	7.466,73
	6.2. PDV 17 %	35.511,46	1.269,34
	7. Ukupna davanja po tarif. oznaci	83.291,60	2.732,35
	Ukupna davanja po carinskoj deklaraciji	86.023,95 KM	
	4.2. Carinska stopa	7,50 %	9 %
	4.3. Carina	12.034,61	539,10
DE	5. Trošarina – stopa 4,28 KM/ kg	45.273,84	1.232,64
	6.1. PDV osnovica (3.2. + 4.1. + 4.3. + 5.)	218.419,23	7.775,47
	6.2. PDV 7 %	15.289,35	544,28
	7. Ukupna davanja po tarif. oznaci	72.597,79	2.316,03
	Ukupna davanja po carinskoj deklaraciji	74.913,82 KM	

Izvor: vlastiti obračun davanja s pomoću carinskog softvera *Daco systems by FastLogistics*

Na obje vrste kave, odnosno tarifne oznake, opet se obračunava isti iznos trošarine kao i u Tablici 2., ali kako ni BiH, ni EU nemaju vanjskotrgovinski spo-

razum s Brazilom, primjenjuju se različite carinske stope – BiH carinska stopa je 10 %, a u SR Njemačkoj primjenjuje se carinska stopa od 7,5 % za prženu kavu s kofeinom (HS oznaka 0901 21 00) i 9 % na prženu kavu bez kofeina (HS oznaka 0901 22 00). Dakle, uslijed carinskih davanja, oba scenarija čine uvoz kave iz Brazila skupljim na obama tržištima (Warenursprung und Präferenzenonline, n. d.).

Možemo zaključiti da je, prilikom usporedbe BiH i SR Njemačke, stopa za 1 % veća na prženu kavu bez kofeina, a za 2,5 % veća na prženu kavu s kofeinom u BiH u odnosu na SR Njemačku. Kako je već navedeno, stope PDV-a različite su u SR Njemačkoj i BiH (slijedom 7 % i 17 %).

U konačnici, prilikom usporedbe stopa carine, trošarine i PDV-a, ukupna davanja po deklaraciji u BiH veća su u odnosu na one u SR Njemačkoj. Na danom primjeru (Tablica 3.), davanja po deklaraciji u BiH veća su za 12,45 % u odnosu na ukupna davanja po deklaraciji u SR Njemačkoj.

6. ZAKLJUČAK I OGRANIČENJA ISTRAŽIVANJA

Bez obzira na harmoniziranost HS oznaka, odnosno nomenklature carinskih tarifa, iz prethodne analize vidljivo je da se carinske politike i prakse BiH i EU-a razlikuju. Europska carinska unija, odnosno EU prema svojoj supranacionalnoj prirodi utvrđuje carinski tretman roba u EU-u, što nije slučaj s BiH. Razlike carinskih stopa nastaju samo unutar različitih kategorija kave, odnosno tarifnih oznaka, ali su po državama članicama iste. Razlike koje postoje vidljive su u visini stopa po tarifnim oznakama, u količini i različitosti vanjskotrgovinskih sporazuma koji daju osnovu za preferencijalno podrijetlo roba, odnosno beneficirani uvozni carinski tretman. Istraživanjem smo ustanovili da jedino robe/kava s uvoznim preferencijalnim podrijetlom imaju jednak carinski tretman u EU-u i BiH za razliku od ostalih analiziranih slučajeva.

Analizom smo pokazali da se u SR Njemačkoj sirova kava s kofeinom ne oporezuje trošarinama, što nije slučaj u BiH. U ostalih pet zemalja članica EU-a koje oporezuju kavu trošarinama, tri članice oporezuju sirovu kavu trošarinama – Grčka, Danska i Belgija, dok to ne čine Hrvatska i Latvija (zajedno s SR Njemačkom, vidi Prilog 1.). Dakle, na primjeru kave možemo vidjeti da, i u slučaju članica EU-a, tržišni uvjeti uvelike doprinose aktualnoj trošarinskoj i poreznoj politici svake zemlje. Također, u prethodnoj analizi vidjeli smo i različite stope PDV-a na kavu u primjeni u BiH i SR Njemačkoj. Iako je recentna akademska

literatura gotovo nepostojeća, prvenstveno zbog praktične prirode istraživane teme, glavne preporuke ovog istraživanja u pravcu su veće akademske zainteresiranosti za navedenu temu, kao i na tragu potencijalne veće harmonizacije trošarinskog tretmana kave u zemljama članicama EU-a kako bi se smanjile i minimizirale interne distorzije koje su identificirane u ovom istraživanju.

Jedno od glavnih ograničenja ovog istraživanja odnosi se na limitiranost dostupne literature, kao i dostupnosti i transparentnosti podataka od strane relevantnih poreznih institucija, posebno u BiH, a za razliku od pristupačnosti i jednostavnosti dostupnosti podataka u EU-u. Podaci koji se od strane poreznih institucija u BiH po zahtjevu elektroničkim putem dostavljaju uglavnom su samo frakcije podataka. Pristup podacima često je administrativno zahtjevan i kompliciran. Istraživanja bazirana na kompletnim uzorcima bolji su temelj za stvaranje zaključaka i donošenja odluka o poreznim politikama i sustavima, odnosno izmjenama aktualnih fiskalnih politika.

REFERENCE

1. Centre for the Promotion of Imports from developing countries. (2022) Entering the European market for coffees roasted at origin. The Netherlands Ministry of Foreign Affairs. Dostupno na: <https://www.cbi.eu/market-information/coffee/roasted-coffees/market-entry> [4. 1. 2023.]
2. Da Silva, I. M (2023, February 1) Explained: Why the EU-Mercosur trade deal could be ratified this year. Euronews. Dostupno na: <https://www.euronews.com/my-europe/2023/02/01/explained-why-the-eu-mercotur-trade-deal-could-finally-be-ratified-this-year> [6. 2. 2023.]
3. Dharmasena, S., & Capps Jr, O. (2012) Intended and unintended consequences of a proposed national tax on sugar-sweetened beverages to combat the US obesity problem. *Health economics*, 21(6), 669-694.
4. Durevall, D. (2007) Demand for coffee in Sweden: The role of prices, preferences and market power. *Food Policy*, 32(5-6), 566-584.
5. EUR-LEX. (2008) Interim Agreement on trade and trade-related matters between the European Community, of the one part, and Bosnia and Herzegovina, of the other part — Protocols. EUR-LEX. Lex — 22008A0630(01) - en - EUR-lex. Dostupno na: <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A22008A0630%2801%29> [6. 2. 2023.]
6. Europska komisija. (n.d.) EU trade relations with Brazil. Dostupno na: https://policy.trade.ec.europa.eu/eu-trade-relationships-country-and-region/countries-and-regions/brazil_en [5. 12. 2023.]
7. Europska komisija. (2022a) Directorate-General for Taxation and Customs Union. Annual report on taxation 2022: Tax policies in the European Union. Publications Office of the

- European Union. Dostupno na: https://op.europa.eu/en/publication-detail/-/publication/n/22508340-1149-11ed-8fa0-01aa75ed71a1/language-en?WT.mc_id=Selectedpublications&WT.ria_c=51677&WT.ria_f=7031&WT.ria_ev=search&WT.URL=https%3A%2F%2Ftaxation-customs.ec.europa.eu%2F [13. 11. 2023.]
8. Europska komisija. (2022b) Excise duties | Access2Markets. Dostupno na: <https://trade.ec.europa.eu/access-to-markets/en/content/excise-duties> [4. 12. 2023.]
 9. Europska komisija. (2022c) Harmonised System | Access2Markets. Dostupno na: <https://trade.ec.europa.eu/access-to-markets/en/content/harmonised-system-0> [5. 2. 2023.]
 10. Europska komisija GSP. (n.d.) Generalised scheme of preferences. Dostupno na: https://policy.trade.ec.europa.eu/development-and-sustainability/generalised-scheme-preferences_en [28. 11. 2023.]
 11. Europska unija. (2022a) General arrangements for excise duty (sa 2023). EUR-Lex. Dostupno na: <https://eur-lex.europa.eu/EN/legal-content/summary/general-arrangements-for-excise-duty-from-2023.html> [20. 2. 2023.]
 12. Europska unija. (2022b) The EU customs union in action. Dostupno na: https://european-union.europa.eu/priorities-and-actions/actions-topic/customs_en [16. 3. 2024.]
 13. Eurostat. (2022a) International trade in goods - tariffs. Dostupno na: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=International_trade_in_goods_-_tariffs#:~:text=The%20EU%20benefits%20sa%20being,the%20EU%20at%20zero%20tariff [5. 2. 2023.]
 14. Eurostat. (2022b) Tax revenue statistics. Dostupno na: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Tax_revenue_statistics [31. 10. 2023.]
 15. Fairtrade Foundation. (2023) Coffee farmers. Dostupno na: <https://www.fairtrade.org.uk/Farmers-and-Workers/Coffee> [15. 12. 2023.]
 16. Federal Ministry for Economic Cooperation and Development. (2021) Minister Müller calls on new German government to grant tax exemption for Fair Coffee. Federal Ministry for Economic Cooperation and Development. Dostupno na: <https://www.bmz.de/en/news/archive-press-releases/mueller-new-german-government-tax-exemption-for-fair-coffee-96118> [25. 2. 2023.]
 17. Feuerstein, S. (1996) Können Produzenten Interesse an einer Verbrauchsteuer auf ihr Produkt haben?/Can Producers Benefit from an Excise Tax on their Product? Warum die deutsche Kaffeesteuer nicht abgeschafft wurde/Why the German Coffee Tax was not Abolished. *Jahrbücher für Nationalökonomie und Statistik*, 215(5), 612-621.
 18. Feuerstein, S. (2002) Do coffee roasters benefit from high prices of green coffee?. *International Journal of Industrial Organization*, 20(1), 89-118.
 19. Generalzolldirektion. (2023) Zoll in Europa. Zur Einfuhr. EZT-Online. Dostupno na: <https://auskunft.ezt-online.de/ezto/Init.do#ziel> [3. 2. 2023.]
 20. Hrvatska enciklopedija, mrežno izdanje. (2021) Leksikografski zavod Miroslav Krleža, 2021. Dostupno na: <http://www.enciklopedija.hr/Natuknica.aspx?ID=10799> [28. 11. 2023.]

21. Međunarodna organizacija za kavu. (2011) The effects of tariffs on the coffee trade. ICC 107 7 E — International Coffee Organization. Dostupno na: <https://www.ico.org/documents/icc-107-7e-tariffs-trade.pdf> [4. 11. 2023.]
22. Jones-Smith, J. C., Walkinshaw, L. P., Oddo, V. M., Knox, M., Neuhouser, M. L., Hurvitz, P. M., ... & Chan, N. (2020) Impact of a sweetened beverage tax on beverage prices in Seattle, WA. *Economics & Human Biology*, 39, 100917.
23. Kutty, P. U. (2000) Demand for coffee imports: an econometric analysis. *Foreign Trade Review*, 35(2-3), 91-100.
24. Lima, U. M., & Lee, K. (2023) Governance and asymmetry in global value chains of the coffee industry: Possibility for catch-up by emerging economies. *Seoul Journal of Economics*, 36(1).
25. Lyssiotou, P., & Savva, E. (2021) Who pays taxes on basic foodstuffs? Evidence from broadening the VAT base. *International Tax and Public Finance*, 28, 212-247.
26. Ministarstvo vanjske trgovine i ekonomskih odnosa Bosne i Hercegovine. (2016) Komentar tarifnog svrstavanja u carinsku tarifu. Ministarstvo vanjske trgovine i ekonomskih odnosa Bosne i Hercegovine. Dostupno na: <http://mvteo.gov.ba/Content/Read/carinska-tarifa?lang=bs> [23. 1. 2023.]
27. Ministarstvo vanjske trgovine i ekonomskih odnosa Bosne i Hercegovine. (2018) Preferencijalno porijeklo. Dostupno na: <http://www.mvteo.gov.ba/Content/Read/porijeklo-robe> [24. 3. 2023.]
28. Ministarstvo vanjske trgovine i ekonomskih odnosa Bosne i Hercegovine. (n.d.). Carinska tarifa za 2022. godinu. Dostupno na: <http://www.mvteo.gov.ba/Content/Read/carinska-tarifa> [4. 1. 2023.]
29. Mohamed, M. B. (2016) *Import tax compliance: a study of customs agents in Malaysia utilising the theory of planned behavior*. Doctoral dissertation. University of Nottingham: Nottingham.
30. Nasution, N., Zamsuri, A., Lisnawita, L., & Wanto, A. (2018) Polak-Ribiere updates analysis with binary and linear function in determining coffee exports in Indonesia. In *IOP Conference Series: Materials Science and Engineering* (Vol. 420, p. 012088). IOP Publishing.
31. Odjeljenje za makroekonomsku analizu. (2021) Analiza naplate prihoda od akciza na alkohol, bezalkoholna pića, pivo, vino i kavu. OMA Bilten broj 193/194. Dostupno na: http://www.oma.uino.gov.ba/bilteni/Oma_Bilten_bos_193_194.pdf [13. 1. 2023.]
32. Preuss, A. (2022) Wie viel Koffein ist im Kaffee, espresso und anderen Getränken? Coffeeness. Dostupno na: <https://www.coffeeness.de/kaffee-koffein/> [15. 12. 2022.]
33. Rotta, N. M., Curry, S., Han, J., Reconco, R., Spang, E., Ristenpart, W., & Donis-González, I. R. (2021) A comprehensive analysis of operations and mass flows in postharvest processing of washed coffee. *Resources, Conservation and Recycling*, 170, 105554.
34. Svjetska banka, (2023) Commodity Markets. Dostupno na: <http://www.worldbank.org/commodities> [7. 12. 2023.]

35. UINO (n.d.) Sporazumi o slobodnoj trgovini. Dostupno na: <https://www.uino.gov.ba/portal/hr/carine-hr/porijeklo-robe-2/> [4. 12. 2023.]
36. Warenursprung und Präferenzenonline. (n.d.) WuP online - CH - Hinweis. Dostupno na: https://wup.zoll.de/wup_online/verarbeitungsliste.php?isoalpha=CH&landinfo=Schweiz&stichtag=26.01.2023&submit_laendersuche=&isoalpha_alt=BA&position=0901 [5. 5. 2023.]
37. World Customs Organization. (2022) Application of Harmonized System Committee decisions Dostupno na: http://www.wcoomd.org/en/topics/nomenclature/instrument-and-tools/tools-to-assist-with-the-classification-in-the-hs/hc_classification-decisions.aspx [5. 2. 2023.]
38. Zakon o akcizama u BiH. (2022) Sl. glasnik BiH, br. 49/2009, 49/2014, 60/2014, 91/2017 i 50/2022. Dostupno na: <https://www.paragraf.ba/propisi/bih/zakon-o-akcizama-u-bosni-i-hercegovini.html> [25. 2. 2023.]
39. Zakon o carinskoj tarifi (2012) Službeni glasnik BiH“, broj 58/12. Dostupno na: https://www.uino.gov.ba/portal/wp-content/uploads/PROPISI/3_Carina/1_Zakoni/H/H-3-Zakon-o-carinskoj-tarifi-5812.pdf [20. 2. 2023.]
40. Zakon o porezu na dodatnu vrijednost Bosne i Hercegovine (2017) Anwalt BiH. Dostupno na: <https://anwalt-bih.de/zakon-o-porezu-na-dodatu-vrijednost-bosne-i-hercegovine> [20. 2. 2023.]

PRILOZI

Prilog 1. Pregled šest članica EU-a i BiH koje oporezuju kavu trošarinama

Članica EU-a	Vrsta trošarine na kavu	Stopa u domaćoj valuti po kg	Domaća valuta	Stopa u EUR po kg
BE	Sirova kava	0,2	EUR	0,2
BE	Pržena kava	0,25	EUR	0,25
BE	Ekstrakti, esencije i koncentрати od kave, čvrsti ili tečni, kao i pripravci na osnovi tih ekstrakata, esencija i koncentrata od kave i pripravci na osnovi kave, obuhvaćene KN oznakom 2101	0,7	EUR	0,7
DK	Sirova kava	6,39	DKK	5,72
DK	Pržena kava	7,67	DKK	6,78
DK	Ekstrakti kave bez drugih sastojaka, osim kave i kave u prahu	16,61	DKK	14,88
LV	Kava, neovisno je li mljevena, pržena ili bez kofeina, ekstrakti, esencije i koncentрати od kave, te proizvodi na osnovi ekstrakata, esencija ili koncentrata od kave	1,42	EUR	1,42
HR	Pržena kava	6	HRK*	0,8
HR	Ekstrakti, esencije i koncentрати od kave	20	HRK	2,65
HR	Pripravci od kave	6	HRK	0,8
HR	Pripravci na osnovi ekstrakata, esencija ili koncentrata 20	20	HRK	2,65
HR	Nadomjesci kave što sadrže kavu iz 0901 90 90	6	HRK	0,8
GR	Pržena kava	3	EUR	3
GR	Nepržena kava (sirova)	2	EUR	2
GR	Ekstrakti, esencije i koncentрати od kave	4	EUR	4
GR	Pripravci na osnovi ekstrakata, esencija i koncentrata od kave i pripravci od kave	4	EUR	4
DE	Pržena kava	2,19	EUR	2,19
DE	Instant-kava	4,78	EUR	4,78
DE	Proizvodi od kave što sadrže prženu kavu 10 g – 100 g	0,12	EUR	0,12
DE	Proizvodi od kave što sadrže prženu kavu 100 g – 300 g	0,43	EUR	0,43
DE	Proizvodi od kave što sadrže prženu kavu 301 g – 500 g	0,86	EUR	0,86
DE	Proizvodi od kave što sadrže prženu kavu 501 g – 700 g	1,32	EUR	1,32

DE	Proizvodi od kave što sadrže prženu kavu 701 g – 900 g	1,76	EUR	1,76
DE	Proizvodi od kave što sadrže instant-kavu 10 g – 100 g	0,26	EUR	0,26
DE	Proizvodi od kave što sadrže instant-kavu 100 g – 300 g	0,94	EUR	0,94
DE	Proizvodi od kave što sadrže instant-kavu 301 g – 500 g	1,91	EUR	1,91
DE	Proizvodi od kave što sadrže instant-kavu 501 g – 700 g	2,86	EUR	2,86
DE	Proizvodi od kave što sadrže instant-kavu 701 g – 900 g	3,83	EUR	3,83
BiH	Nepržena kava s i bez kofeina	1,5	EUR	0,766
BiH	Pržena kava s i bez kofeina	3	EUR	1,53
BiH	Ostali proizvodi: kavine ljuske i opne, nadomjesci kave što sadrže kavu, ekstrakti, esencije i koncentracije, i pripravci na osnovi ekstrakata, esencija ili koncentrata od kave i ostali pripravci	3,5	EUR	1,78

* HRK za promatrano razdoblje

Izvor: vlastita usporedba kreirana na osnovu podataka Europske komisije (Europska komisija, 2022b) i zakonodavstva BiH.

COMPARATIVE ANALYSIS OF CUSTOMS AND EXCISE TREATMENT OF COFFEE IN THE EU AND BIH

Lejla Lazović-Pita, PhD

School of Economics and Business, University of Sarajevo

e-mail: lejla.lazovic@efsa.unsa.ba

Maida Tahirović, MA

I-Logistics d.o.o. Sarajevo

e-mail: maida.tahirovic@gmail.com

ABSTRACT

The treatment of coffee in terms of customs and excise is a topic that receives very little attention in theoretical and practical academic research. The purpose of this paper is to provide a practical comparison of customs and excise duties on coffee in Bosnia and Herzegovina (BiH) and Germany, a representative of the EU members and the largest importer of coffee in the EU. The analysis is conducted separately for two scenarios: coffee imports with and without preferential schemes. The results of the comparative analysis show that there are no differences in the customs HS classification of coffee in Germany and BiH. However, our results also indicate that differences in the total amount of duties paid on imported coffee in BiH and Germany depend on the existence of customs preferential schemes and the specifics of the excise treatment of coffee.

Key words: coffee, customs, excise duty, Bosnia and Herzegovina, EU

JEL classification: H2

DISKRECIJSKO PRAVO I PRAVEDNOST U KONTEKSTU TRANSFERNIH CIJENA

prof. dr. sc. Ivo Mijoč

Ekonomski fakultet u Osijeku
Sveučilište Josipa Jurja Strossmayera u Osijeku
e-mail: ivo.mijoc@efos.hr

dr. sc. Dubravka Kopun ml.

Kopun Group
e-mail: dkopun@yahoo.com_

doc. dr. sc. Ivan Čevizović

Čevizović j.t.d.
e-mail: ivan.cevizovic@cevizovic.eu

SAŽETAK

Regulacija dobiti ili cijena u ovisnosti o tendenciji graničnih troškova proizvodnje i poreznih performansi koreliraju s internim politikama poduzeća o količinama uvoza i izvoza čineći transferne cijene opravdanim instrumentom međunarodne trgovine. Cilj rada bio je, na uzorku od 280 IT poduzeća u trogodišnjem razdoblju, analizirati stupanj poreznog opterećenja i profitabilnosti usporedbom poduzeća u hrvatskom vlasništvu u odnosu na poduzeća u inozemnom vlasništvu. Osnovna namjera rada počiva na definiranju razlika između poreznih rezidenata i nerezidenata te utvrđivanja uspješnosti poslovanja IT poduzeća primjenjujući metodologiju opisanu kroz Smjernice OECD-a. Primjenom financijskih pokazatelja i interkvartilnih raspona, dobiveni rezultati upućuju kako su tuzemni rezidenti u nepovoljnijem poreznom položaju u odnosu na nerezidente, ali pri tome ostvaruju veću profitabilnost poslovanja. Utvrđeni nesrazmjer otvara pitanje diskrecijskog prava i pravednosti transfernih cijena, o čemu se u radu raspravlja te predlažu moguća rješenja.

Ključne riječi: transferne cijene, OECD-ove Smjernice, profitabilnost, financijski pokazatelji, interkvartilni rasponi

JEL klasifikacija: H25, H26, M40, M41

1. UVOD

Razvojem gospodarstva i globalizacijom poslovanje se počelo širiti preko granica pojedinih država, u početku na susjedne države, kasnije i na druge kontinente. Iako je originalno prelazak u druge države, odnosno druga tržišta, motiviran širenjem tržišta za proizvode i/ili usluge, neminovno je došlo do pojave pojedinih poreznih implikacija. Naime, oporezivanje dobiti zbog nejednačenih poreznih sustava u različitim poreznim jurisdikcijama (državama) može biti pod različitim tretmanima, čime postaje poželjno premještati dobit iz jedne države u drugu – iz države s većim poreznim opterećenjem u državu s manjim poreznim opterećenjem. Prikladan način kako se navedeno može ostvariti jesu transferne cijene. Jasno, opisano vrijedi za transakcije između povezanih osoba koje imaju određene koristi od ovih transakcija. Iako problem transfernih cijena može biti od utjecaja i na rezidente jedne države, uobičajeno se ovo povezuje s transakcijama koje uključuju različite države (porezne jurisdikcije).

U osnovi, ideja određivanja transfernih cijena relativno je jednostavna – cijene između povezanih osoba moraju biti onakve kako bi ih u istim uvjetima ugovorile nepovezane osobe. Dakle, to su interno određene cijene koje prema Clausingu (2000) čine veliki udio u međunarodnoj trgovini od 1977. godine obuhvaćajući 36 % američkog izvoza i 43 % američkog uvoza. Međutim, iza ovog relativno jednostavnog koncepta kriju se brojni problemi (Bartelsman i Beetsma, 2000, str. 3). Prije svega, pitanje sadržaja transakcije i alokacije rizika koji preuzima pojedina od povezanih osoba. Upravo funkcionalna analiza grupe bit će temelj dokumentacije o transfernim cijenama pomoću koje pojedina društva i porezni obveznici dokazuju nadležnim poreznim upravama prikladnost cijene. Nadalje, pitanje marketinških, postprodajnih i drugih sličnih aktivnosti praktično je nemoguće jednoznačno alocirati na povezane osobe u definiranju lanca stvaranja vrijednosti. Potom, osiguranje financijskih sredstava, preuzimanje kreditnog rizika i valutnog rizika također može biti od izravnog učinka na očekivanu distribuciju vrijednosti. Sve navedeno zato što matično društvo može, prema geografskim obilježjima, osnivati različita ovisna društva i tako izravno utjecati na visinu ostvarene dobiti tako da djelomično ili u potpunosti umanju obvezu plaćanja poreza na dobit i, pri tome, koristiti određene porezne olakšice (Elitzur i Mintz, 1996, str. 402).

Metodologija transfernih cijena područje je koje posljednja dva desetljeća značajno dobiva na značaju – jednim dijelom zbog sve naglašenije globalizacije poslovne aktivnosti, a drugim dijelom uslijed činjenice da je postojeći okvir

transfernih cijena formiran prije gotovo stotinjak godina zbog čega se pitanja vezana uz oporezivanje novih digitalnih komponenti pokušavaju razriješiti posljednjih godina davanjem u raspravu okvira Pillar 1 i Pillar 2. Naime, postojeće OECD-ove Smjernice za transferne cijene dominantno su okrenute k proizvodnim i trgovačkim poduzećima, odnosno nedostatne su u segmentu uslužnih djelatnosti, što uključuje i IT industriju. Navedeno je posebice izraženo značajnom digitalizacijom i promjenama načina poslovanja s „fizičkog gospodarskog okruženja“ na „internetsko okruženje“. Temeljni elementi globalnog poreznog sustava koji su određivali gdje se treba plaćati porez (tzv. „nexus“ pravila temeljena na fizičkoj prisutnosti) i koji dio dobiti treba oporezivati (tzv. „profit allocation“ pravila temeljena na načelu neovisnosti - *arm's lenght principle*) povijesno su bila dobra osnova za oporezivanje (OECD, 2022). U središtu nove rasprave u segmentu transfernih cijena jest reorganizacija poreznih propisa vezanih uz međunarodno oporezivanje u skladu s modernim globalnim gospodarstvom, pri čemu treba eliminirati dvostruko oporezivanje kako bi se stimulirala međunarodna trgovina. U tu je svrhu, OECD (Organizacija za ekonomsku suradnju i razvoj) u listopadu 2020. godine objavio prijedlog Pillar 1 i Pillar 2, odnosno prijedlog okvira oporezivanja multinacionalnih društava s naznakom na novo digitalno okruženje.

Rad sadržava pet naslova. Nakon uvodnih razmatranja, predstavljene su osnovne karakteristike IT industrije u nacionalnom okviru. Teorijski pregled literature, segmentiran u četiri dijela, omogućuje uvid u opće poimanje transfernih cijena kroz Hyde-Choe model u odnosu na harmonizacijska očekivanja OECD-a. Potom su opisane polazišne pretpostavke te oblikovane hipoteze, čime su ostvareni metodološki aspekti rada. Središnji dio rada nastavlja s predstavljanjem rezultata analize i rasprave na temelju čega je oblikovan Zaključak rada.

1.1. SVRHA I CILJ RADA

Uzevši u obzir činjenicu kako su digitalne usluge osnova četvrte industrijske revolucije s perspektivom budućeg rasta i razvoja uz povećanje profitabilnosti (Hrbić i Grebenar, 2021, str. 33) cilj rada jest analizirati stupanj poreznog opterećenja i profitabilnosti poduzeća u hrvatskom vlasništvu u odnosu na poduzeća u inozemnom vlasništvu iz J62 skupine obuhvatom razdoblja od 2019. do 2021. godine. Promatrano razdoblje ključno je zbog toga što OECD-ove Smjernice za transferne cijene dopuštaju *benchmark* analizu usporedbom

kvartila za trogodišnje razdoblje. Pri tome su fokus ovog rada isključivo poduzeća s ostvarenim prihodima većim od 7,5 mil. HRK u 2021. godini, jer u svojoj strukturi mogu značajnije utjecati na ostvarenje zaposlenosti i profitabilnosti poslovanja. Osnovna namjera rada jest definirati uspješnost poslovanja navedenih poduzeća primjenom financijskih pokazatelja te utvrditi postojanje razlika između poreznih rezidenata i nerezidenata s aspekta transfernih cijena. Porezni su rezidenti poduzeća iz IT sektora u domaćem vlasništvu u odnosu na tuzemne nerezidente opisane kao poduzeća u inozemnom vlasništvu. Na temelju prikupljenih podataka izvršene su usporedbe poreznog opterećenja i profitabilnosti u ovisnosti o vrsti vlasništva u IT industriji na temelju interkvartilnih vrijednosti za različite procjenitelje profitabilnosti.

2. OPĆENITO O IT INDUSTRIJI U HRVATSKOJ

Na temelju pregleda hrvatske IT industrije, sačinjenog od strane Hrvatske gospodarske komore (HGK, 2020, str. 7-8), IT poduzeća mogu se podijeliti u sljedeće kategorije: (a) IT uslužna poduzeća, koje najveći dio svoje dodane vrijednosti generiraju pružanjem IT usluga, a koje uključuju i razvoj i programiranje softvera po narudžbi; (b) softverski vendori (ISV), koji najveći dio svoje dodane vrijednosti ostvaruju razvojem gotovih, pakiranih softverskih proizvoda, odnosno prodajom licenci, te s njima povezanog održavanja i naknada za uporabu aplikacija u oblaku; (c) proizvođači IT opreme i komponenti, koji pretežiti dio svoje dodane vrijednosti ostvaruju proizvodnjom softverom prožetih proizvoda, hardverskih komponenti i sastavljanjem osobnih računara; (d) tvrtke pružatelji *outsourcing* IT usluga, koje pružaju IT usluge trećima. U ovu kategoriju uključene su tri skupine poduzeća: (i) velike tvrtke u javnom vlasništvu, koje pružaju usluge *outsourcinga* informatičkih sustava te upravljanja i *hostinga* aplikacija za tijela središnje i lokalne uprave, (ii) izdvojene (*spin-off*) privatne tvrtke koje obavljaju informatičku funkciju za matična poduzeća te (iii) izdvojene IT funkcije banaka i ona koja se bave procesiranjem kartičnog poslovanja te, u konačnici, (e) trgovce IT opremom, koji najveći dio svoje dodane vrijednosti ostvaruju prometom IT opreme i s njom povezanih komponenti, rezervnih dijelova, raznih dodataka i potrošnog materijala te paketnog softvera.

Pregled broja poduzeća, broja djelatnika, ostvarenog prihoda na bazi podataka iz financijskih izvještaja za 2019. godinu dan je Tablicom 1. Digitalizacija, jednim dijelom, u velikoj mjeri ubrzana zbog globalne pandemije dovodi do značajnog utjecaja IT industrije na poslovanje. Predmetni prihodi u 2021. godini,

uvjetovani ograničenjem poslovanja uzrokovanih bolešću COVID-19, rasli su za visokih 19 % u odnosu na usporednu 2020. godinu. Prihodi IT sektora u 2021. godini iznosili su 17,3 milijardi kuna, od čega je izvoz sačinjavao 7,2 milijarde, odnosno gotovo 42 % (Barančić, 2021).

Tablica 1. Pregled poduzeća iz IT sektora po vrstama djelatnosti

Vrsta IT poduzeća	Broj poduzeća	Broj djelatnika	Prihodi 2019. (u mlrd kn)
IT uslužna poduzeća	2.227	15.646	11,30
Softverski vendori (ISV)	302	9.250	5,21
Proizvođači IT opreme	46	1.348	697,07
Outsourcing IT usluga	18	2.346	1,99
Trgovci IT opremom	231	2.521	7,25

Izvor: HGK (2020). Analiza hrvatske IT industrije 2014. – 2019.

Iako postoji veliki broj poduzeća u ovom segmentu (više od 5000), svega 400-tinjak poduzeća zapošljava više od 10 djelatnika te ostvaruje pretežiti dio prihoda i dobitaka IT sektora. Paralelno, s ubrzanom digitalizacijom zamjetna je i konsolidacija u ovom sektoru – jednim dijelom klasičnim oblicima preuzimanja i spajanja uz istovremeni ulazak međunarodne fondovske industrije u hrvatski IT sektor. Takvim se pristupom osigurava daljnji razvoj IT industrije u nacionalnom kontekstu, primarno promjenom vlasničke strukture, uvjetujući izmjene načina funkcioniranja poslovanja premještanjem dijela poslovnih aktivnosti (prodaja) izvan tuzemnih regulatornih okvira. Opisana promjena načina poslovanja u daljnjim koracima dovodi do manjeg prihoda i profitabilnosti hrvatskih IT poduzeća, što je uvjetovano elastičnijim načinom organiziranja poslovanja. S aspekta transfernih cijena navedeno podrazumijeva promjenu modela samostalnog poslovanja na vrlo često „kooperantski model“, što, u konačnici, ima izravan utjecaj na visinu i stupanj profitabilnosti hrvatskih poduzeća. U takvom poslovnom odnosu, hrvatsko IT društvo primorano je koristiti model „troškovi plus“ (C+) zahvaljujući velikim dijelom činjenici da hrvatsko IT poduzeće osigurava samo dio aktivnosti iz lanca vrijednosti. Ostvarena naknada izražena kao prihod u pravilu se definira u visini ostvarenih troškova uvećanih za određenu maržu. Na taj način sve koristi vezane uz ostvarenje prihoda i oporezivanje porezom na dobit ostaju u zemlji matici u kojoj se poslovanje organizira.

Ključan razlog uvođenja novog okvira oporezivanja jest činjenica kako današnje digitalne usluge zahtijevaju drugačiji sustav globalnog oporezivanja. Novo

digitalno doba zahtijeva i drugačiji pristup oporezivanju. Navedeno je posebice izraženo kod digitalnih usluga (npr. usluge *streaminga* kao Netflix, korištenje *cloud* platformi kao Google Drive, Dropbox i sl.), gdje se porez na dobit plaća isključivo u zemlji matici koja pruža uslugu, iako se korisnici nalaze lokalno.

3. TEORIJSKI PREGLED LITERATURE I OBLIKOVANJE HIPOTEZA

3.1. PREGLED DOSADAŠNJIH RELEVANTNIH ISTRAŽIVANJA

Uvidom u dostupna empirijska istraživanja zaključuje se kako brojni praktičari i znanstvenici nerijetko provode istraživanja u širem kontekstu transfernih cijena. U ovom dijelu rada isključivo su prikazani rezultati znanstvenih studija koji ističu prednosti, nedostatke i učinke transfernih cijena.

Horst (1971) je postavio temeljni model odabira strategije transfernih cijena multinacionalnih kompanija za maksimiziranje dobiti nakon oporezivanja u odnosu na monopolistička poduzeća koja prodaju usluge istovremeno na dva tržišta. Interne odluke poduzeća o količini proizvodnje i prodaje, dakle politika cijena, u smislu uvoza i izvoza, ovise o tendenciji graničnih troškova proizvodnje te o poreznim performansama koje treba savršeno razlikovati na dva nacionalna tržišta, što prema Clausingu (2000) omogućuje poduzeću odabir između najniže ili najveće moguće cijene transfera ovisno o usporedbi relativnih razlika u poreznim stopama među zemljama. Međutim, Schjelderup i Weichenrieder (1999) tvrde kako trgovinski učinak čini promjenu pravila o transfernim cijenama potencijalnim instrumentom protekcionizma i strateške trgovinske politike jer se veće smanjenje međunarodne trgovine ostvaruje regulacijom dobiti, a ne izravnom regulacijom cijena. Dobiveni zaključci Schjelderupa i Weichenrieder (1999) mogu se objasniti s aspekta ovisnog društva – izvoznika, pri čemu regulacija dobiti potiče neutralnu trgovinu rezultirajući konstantnim graničnim troškovima, zbog čega metodu usporedive dobiti treba promatrati iz GATT perspektive (Opći sporazum o carinama i trgovini). Stewart (1989) je analizirao trgovinsku statistiku dodane vrijednosti u području kemikalija i hrane na temelju cijena uvoza i izvoza naglašavajući kako su cijene bile u skladu s prebacivanjem dobiti u Irsku korištenjem transfernih cijena, što Irsku označuje kao poreznu oazu, iako nije tako klasificirana prema OECD-ovim kriterijima, što omogućuje značajne uštede i porezne olakšice za nekoliko velikih multinacionalnih kompanija iz SAD-a. Upravo je Irska, sa sto-

pom od 12,5 % poreza na dobit, posljednjih 20-ak godina, privukla veliki broj međunarodnih korporacija, posebice iz IT sektora (Google, Microsoft, Intel, Apple, Facebook). Koliko je porez na dobit u Irskoj značajna kategorija govori podatak da za usporedbu od Hrvatske, u čiji se državni proračun slijeva svega 5,6 % priljeva s osnove poreza na dobit, u Irskoj je taj postotak čak 20 % (11,8 milijardi USD), stoji u objavi Kopun Grupe (2021). Stoga nije čudno da su Sikka i Willmott (2010) predstavili tamne strane transfernih cijena kao potporne elemente u izbjegavanju poreza i zadržavanju bogatstva.

Većina istraživačkih studija procjenjivale su veličinu porezne indukcije transfernih cijena, gdje Clausing (2000) posebno ističe studije Lall (1973) u segmentu proizvođačkih djelatnosti, Jenkins i Wright (1975) te Bernard i Weiner (1990) analize naftne industrije SAD-a, Kopits (1976) objašnjava učinke internih cijena, porezne implikacije istraživali su Grubert i Mutti (1991), dok su Hines i Rice (1994) te Collins, Kemsley i Lang (1996) pojasnili porezne oaze i vrednovanje zarada između jurisdikcija, respektivno. S druge strane, mnogi autori ukazali su kako transferne cijene mogu utjecati na trgovinu unutar poduzeća. Vicardovi (2015) rezultati, na temelju proučenih detaljnih podataka o izvozu i uvozu Francuske, pokazuju kako cjenovni klin između načela neovisnosti i povezanih poduzeća varira s razlikom uključene porezne stope, što je smanjilo francusku osnovicu poreza na dobit za 8 milijardi USD u 2008. s tendencijom rasta i daljnje erozije porezne osnovice. Marques i Pinho (2016) indeksom rigidnosti okvira transfernih cijena i razlika u poreznim stopama promatrali su strategije prebacivanja prihoda europskih MNC-a u razdoblju od 2001. do 2009. godine. Rezultati sugeriraju obrnuto proporcionalan odnos promatranih varijabli, što dokazuje kako je pooštrevanje okvira transfernih cijena sposobno obeshrabriti međunarodna poduzeća od seljenja dobiti iz zemalja s višim u zemlje s nižim poreznim opterećenjima. Slično, Lohse, Riedel i Spengel (2014) ispitivali su 44 zemlje analizirajući razvoj različitih aspekata propisa o transfernim cijenama, u istom vremenskom razdoblju, kategorizacijom nacionalnih okvira s obzirom na njihovu strogost i učinak. Rezultati kategorizacije potvrđuju ne samo sve veću važnost propisa o transfernim cijenama, već nude vrlo korisne i vrijedne informacije za buduća istraživanja o utjecaju propisa o transfernim cijenama na korporativne odluke. Primjerice, zemlje u kojima postoje propisi o transfernim cijenama obično se primjenjuju samo na povezana poduzeća primjenom tradicionalnih metoda u odnosu na metode transakcijske dobiti, pri čemu su europski regulatorni okviri manje strogi u usporedbi s 80 % zemalja izvan Europe. Tijekom vremena globalni naponi rezultirali su većim stupnjem usklađenosti regulatornih okvira za transferne cijene

u EU-u jer sve zemlje slijede OECD-ove Smjernice, načela nepristranih transakcija i predložene metode vrednovanja prikladnosti cijena, što je u skladu sa zaključcima istraživanja Perčević (2015) te Sopte, Bilas i Jakupović (2021).

3.2. HYDE-CHOEOV MODEL TRANSFERNIH CIJENA

Teorijske pretpostavke uzimaju u obzir opći strukturni Hyde-Choeov model transfernih cijena (2005, str. 169-171): Multinacionalno društvo (MNC) ima dva povezana društva, K i D. S_K matično je društvo koje nudi određene usluge i količinu q_K usluge u zemlji K. Povezano društvo S_D ima ulogu ovisnog društva koje kupuje q_D usluge po cijeni p i prodaje je u zemlji D. U početnoj pretpostavci, osnovni model zasniva se na nereverzibilnom modelu te pretpostavci kako samo ovisno društvo kupuje od matice (S_D vs. S_K) i samostalno utvrđuje vrijednost q_D , koja čini internu prijenosnu cijenu I_{TP} . Samostalno određivanje I_{TP} ovisnog društva S_D jest središnja tvrdnja modela, dok u obrnutom scenariju poticajne transferne cijene ne bi imale smisla ako bi S_K određivao kriterije za q_D . Uz pretpostavku linearnosti troškova u S_K i S_D , trošak matice zapisuje se kao $T(qK + qD)$, odnosno $t(qK + qD)$, gdje je $t > 0$. Troškove marketinga i distribucije anulira MNC $T = t = 0$ uz postojanje troška transakcije kupnje usluge. Potražnja na tržištu L čini $pL(q)$, pL je cijena na tržištu L, dok je ostvareni prihod na tržištu L označen kao $R_L(q)$, čime se smanjuje granični prihod poduzeća na oba tržišta. Primjerice, povezano društvo prodaje 100 komada jedinica usluge A za ukupan iznos od 500 NJ. Ako se sljedećih 5 usluga unovči za dodatne 24 NJ granični prihod za dodatnih 5 komada iste usluge smanjio se za 0,20 NJ jer se uzima inkrementalna promjena. Ako poduzeće proda 110 komada iste usluge za 560 NJ, granični prihod za 5 isporučenih jedinica usluge A jest 36 NJ ili 7,20 NJ po jedinici usluge. Uvažavanjem ograničenja matice S_K određuje prodajnu količinu q_K i dvije transferne cijene kako bi se povećala konsolidirana dobit nakon oporezivanja $\pi_{MNC} = \pi_K + \pi_S$. Potom, S_D prihvaća povećanje dobiti nakon oporezivanja podružnice kupnjom q_D .

Dakle, Hyde-Choeov model (2005) problematizira delegiranje silazne odgovornosti na ovisno društvo oko određivanja količine jer ovisno društvo teži povećanju vlastite umjesto konsolidirane dobiti. Premda je matica vlasnik ovisnog društva te neizravno kontrolira količine nabave ovisnog društva, kroz modele određivanja cijena, primaran izostanak kontrole nad količinama održava se na teret dobiti matičnog društva u odvojenim financijskim izvještajima matice.

3.3. OECD-OVI MODELI TRANSFERNIH CIJENA

OECD je, u listopadu 2020., objavio prijedlog Pillar 1 i Pillar 2 (tj. GloBE pravila), odnosno prijedloge okvira oporezivanja multinacionalnih poduzeća s naznakom za novo digitalno okruženje. Pillar 1 fokusira se na skup pravila za oporezivanje dobiti i prava definirajući formulu za izračun udjela dobitka (Hannappi i González Cabral, 2020), koja se oporezuje unutar svake pojedinačne porezne jurisdikcije (Marques i Pinho, 2016, str. 709-710). Navedeno je posebice ključno kod digitalnih usluga gdje se tržište nalazi u jednoj zemlji, dok se usluga obavlja iz neke druge zemlje (npr. *cloud* rješenja, *streaming* servisi i sl.). Ključni elementi prvog stupa mogu se grupirati u tri komponente (OECD, 2022, str. 12): (i) nova pravila oporezivanja za tržišne jurisdikcije na udio preostalog profita izračunatog na razini grupe ili segmenta (Iznos „A2”) (Lubis i Rahayu, 2021; Graetz, 2021; Collier i dr., 2021; OECD, 2020; Avi-Yonah i dr., 2008), (ii) fiksni povrat za definirane osnovne marketinške i distribucijske aktivnosti koje se fizički odvijaju u tržišnoj jurisdikciji u skladu s načelom nepristrane transakcije (Iznos „B”) (Higinbotham i dr., 2021; Navarro, 2021; de Wilde, 2019) te (iii) poboljšani procesi porezne sigurnosti za povećanje porezne sigurnosti kroz inovativne mehanizme za sprječavanje i rješavanje sporova (komponenta porezne sigurnosti, tj. Iznos „C” = „A” + „B”) (OECD, 2022a; OECD, 2022b; Hearson, 2020). Konkretno, iznos „A” baziran na oporezivanju „ekstra” bruto profitabilnosti iznad definiranih 10 % i to tako da se dio oporezuje porezom na dobit svake pojedine zemlje gdje se prihod i ostvaruje te iznos „B”, kojim se definira plaćanje poreza na dobit u zemljama gdje su aktivnosti marketinga i distribucije, odnosno porez na dobit plaćat će se zbog same činjenice da se tržište nalazi lokalno.

Pillar 2 fokusira se na minimalnu stopu poreza na dobit od 15 % kako bi se obeshrabile multinacionalne kompanije u provedbi porezne optimizacije tako da se dobitci iz jedne jurisdikcije prebacuju u zemlje s nižim poreznim opterećenjem pomoću složenih sporazuma (Perčević, 2022). *Prima facie*, GloBE pravila obuhvaćaju pravilo uključivanja prihoda (IIR), pravilo o neoporezivom plaćanju (UTPR), inozemno kontrolirano društvo (CFC), a *switch-over* pravilo (SOR) i pravilo o podlijevanju porezu (STTR) (Wardell-Burrus, 2023; Apriliasari, 2021). Ako ova poduzeća u nekim zemljama plaćaju manju stopu poreza na dobit od propisane u visini od 15 %, u obvezi su obračunati i platiti razliku do predmetnih 15 % prema IIR pravilu. Ako se radi o povezanom društvu koje se nalazi u zemlji s niskim porezom, koje ne podliježe porezu prema IIR pravilu, tada prema UTPR pravilu o neoporezivom plaćanju, matično druš-

tvo ne može s poreznog aspekta odbiti troškove povezanog društva dok ne ostvari visinu minimalne stope poreza na dobit od 15 %. Jednostavnije rečeno, multinacionalne kompanije u svakoj zemlji imaju obvezu platiti minimalnu stopu poreza na dobit od 15 %. Iznimno, u situacijama kada sama zemlja nema ovakvo pravilo i ne prihvaća minimalnu stopu poreza na dobit od 15 %, tada matično društvo multinacionalne grupe ima obvezu platiti razliku iz ovih pojedinih zemalja koje nisu prihvatile minimalnu stopu poreza na dobit u zemlji gdje se nalazi matično društvo. De Broe i dr. (2019, str. 3) tvrde kako je očito da je ovaj dio GloBE prijedloga inspiriran američkim pravilima o globalnoj nematerijalnoj niskooporezivoj dobiti („GILTI“) (Odjeljak 951A Poreznog zakona SAD-a). Pillar 2, prema OECD-u (2022, str. 13), upućuje na preostale BEPS (Erozija porezne osnove i premještanje dobiti) izazove putem niza međusobno povezanih pravila kojima se nastoji: (i) osigurati minimalno oporezivanje uz izbjegavanje dvostrukog oporezivanja ili oporezivanja gdje nema ekonomske dobiti, (ii) nositi se s neusklađenim oblicima nacionalnih poreznih sustava kao i s različitim operativnim modelima poduzeća, (iii) osigurati transparentnost i jednake uvjete te (iv) smanjiti administrativne troškove i troškove usklađivanja (Riccardi, 2021), dok bi kod suprotnog djelovanja prekomjerni porez mogao biti plaćen u drugoj jurisdikciji.

U iznimno vertikalno ustrojenom sustavu, definiranje tržišnih odnosa između povezanih osoba iznimno je zahtjevno, posebice u slučaju uslužnih djelatnosti poput programerskih usluga. Pri tome, OECD objavljuje i izdaje Smjernice za transferne cijene za multinacionalna poduzeća i porezne uprave (OECD-ove Smjernice). Predmetne smjernice predstavljaju osnovu prilikom utvrđivanja načela neovisnosti (engl. *arm's length principle*). Iako Hrvatska nije OECD-ova članica te se u zakonodavnom okviru, ponajprije u Zakonu o porezu na dobit, ne poziva na odredbe OECD-ovih Smjernica, potiče se praćenje poslovanja multinacionalnih poduzetnika primjenom standardizirane metodologije. Kako je Hrvatska u srpnju 2022. godine službeno započela pregovore oko ulaska u OECD za očekivati je dugoročno da će predmetne Smjernice ujedno biti u cijelosti obvezne za primjenu i prilikom definiranja prijave poreza na dobit za multinacionalna poduzeća. Osiguranje provedbe načela neovisnosti za utvrđivanje transfernih cijena OECD-ove Smjernice omogućavaju primjenom većeg broja metoda (OECD, 2022, str. 95). U standardne transakcijske metode ubrajaju se metoda usporedive nekontrolirane cijene, metoda preprodajne cijene i metoda troškovi plus, dok metode temeljene na dobitku uključuju metodu podjele dobitka, metodu neto dobitka u cijeni (*TNMM*) i metodu usporediva dobitka. U praksi se u velikom broju slučajeva koristi *TNMM* metoda koja prema nekim

analizama sudjeluje s više od 50 % analiza transfernih cijena (Treidler, 2020, str. 52). Ova metoda mjeri neto operativnu dobit ostvarenu od kontroliranih transakcija te istu uspoređuje s razinom dobiti koju su ostvarila neovisna društva koja sudjeluju u usporedivim transakcijama. Stoga, TNMM metoda ispituje neto dobiti na odgovarajuću osnovicu (npr. troškovi, prodaja, imovina), koju porezni obveznik ostvaruje iz kontrolirane transakcije i isto uspoređuje s neto dobiti ostvarenom u usporedivim nekontroliranim transakcijama.

3.4. POLAZIŠNE PRETPOSTAVKE I OBLIKOVANJE HIPOTEZA

Prevelika kapilarnost malih poduzeća s jednim ili neznatno većim brojem zaposlenih, koja pretežno izvršavaju usluge na zahtjev u smislu ustupanja posla (agencijski posao) ili su uključena u određeni segment izvršenja usluge ne pridonosi stvaranju dodanih vrijednosti. Tijekom 2014. godine broj klasificiranih poduzeća u skupini J62 iznosio je 3497 i u petogodišnjem razdoblju dosegao je broj od 4670, čime je broj poduzeća u Hrvatskoj rastao brže od prosjeka EU28 za 7,1 % (HGK, 2020, str. 61). Sličan trend zabilježen je u Bugarskoj, Rumunjskoj i Mađarskoj. Zapravo, na mikrorazini, opisana usitnjenost rezultat je pogodnog hrvatskog zakonodavnog okvira i poreznog planiranja. Time IT poduzeća primjenom načela porezne evazije osmišljavaju različite oblike porezne optimizacije poslovanja, što, obično, podrazumijeva registraciju paušalnog obrta ili jednostavnih oblika trgovačkih društava čime se opravdavaju visoki operativni troškovi poslovanja. Navedeno je, posebice, izraženo značajnom digitalizacijom i dematerijalizacijom poslovanja. Tuzemni porezni rezidenti obveznici su obračuna poreza na dobit sukladno nacionalnim zakonskim okvirima u odnosu na tuzemne nerezidente koji koriste različite zakonodavne mogućnosti seljenja dobiti u povoljnije porezne jurisdikcije iz kojih se zaračunavaju naknade (*royalty fee* i sl.) društvima u redovnim poreznim sustavima na gornjoj granici prihvatljivog poreznog opterećenja, pri čemu se navedena promjena može promatrati kroz račun dobiti i gubitka (RDG). Stoga, se H1 može oblikovati kao: Tuzemni porezni obveznici imaju veće porezno opterećenje u odnosu na tuzemne porezne nerezidente. Hipoteza je testirana tako da se u konačnom uzorku usporedilo prosječno porezno opterećenje u trogodišnjem razdoblju.

Za praćenje poslovanja IT poduzeća koriste se interkvartilni rasponi uobičajenih pokazatelja radi zabilježbe učinaka transfernih cijena. Operativno, u praksi su, prema Greil i Greil (2021, str. 64-65), uočeni brojni pokazatelji od kojih je potrebno izdvojiti: (i) povrat na prodaju (ROS) primjenjiv kod distributera pro-

izvoda koji ne stvaraju jedinstveni i vrijedan doprinos, za prodajna poduzeća ili kod poduzeća, gdje imovina i zalihe nemaju značajniji utjecaj na profitabilnost poslovanja; (ii) povrat na imovinu (ROA) i povrat na angažirani kapital (ROE) specifičan kod proizvođača koji raspolažu s vrijednom imovinom neophodnom za stvaranje dobitaka; (iii) povrat na troškove (ROC) karakterističan za davatelje usluga, uključujući ugovorne proizvođače i usluge istraživanja i razvoja te (iv) Berry omjer koji se koristi prilikom analize posrednika s ograničenim rizikom. Kod analize dostatne dobiti nerezidenta, ostvarene u zemlji domaćina uspoređuju se vrijednosti s rasponima između Q1(25th) i Q3(75th) usporednih poduzetnika, a potom se koreliraju s interkvartilnim omjerima SAD-a.

Osim uobičajenih pokazatelja izračunati su drugi procjenitelji profitabilnosti poput stupnja vlastitog financiranja, EBITDA, ROA i postotak bruto dobiti. IT poduzeća nemaju dugotrajnu imovinu pa nemaju ni potrebu za većim novčanim sredstvima, stoga je zamjetno interno financiranje kroz kapital umjesto skupog i neizvjesnog vanjskog financiranja dugom. IT sektor jest radno intenzivna djelatnost jer je ljudska komponenta presudni čimbenik u stvaranju dobiti, pri čemu se navedena promjena može promatrati kroz Bilancu. Stupanj vlastitog financiranja kod rezidenata veći je u odnosu na poduzeća u inozemnom vlasništvu. Osim toga, porezni rezidenti potaknuti većim poreznim opterećenjem pribjegavaju alternativnim i kompromisnim rješenjima, što obično podrazumijeva osnivanje ovisnih ili sestrinskih društava u poreznim jurisdikcijama s nižim poreznim opterećenjem. U okruženju transfernih cijena povoljnija opcija jest osnivanje sestrinskih poduzeća, jer ne podliježu BEPS 15 pravilu niti su dužni prikazati inozemno kontrolirano društvo. Može se pretpostaviti kako interkvartilni rasponi uobičajenih pokazatelja i dodatnih procjenitelja za praćenje transfernih cijena u poslovanju IT rezidenata trebaju biti viši u nacionalnom okviru te sukcesivno na razini pokazatelja SAD-a djelovanjem OECD-ova načela u globalnom kontekstu. U konačnici, hipoteza (H2) tvrdi kako: Raspon interkvartila IT poduzetnika rezidenata jest veća u odnosu na IT nerezidente.

4. METODOLOGIJA ISTRAŽIVANJA I OPIS PRIKUPLJENIH PODATAKA

4.1. PRIKUPLJANJE PODATAKA

Prikupljeni su FINA GFI podaci za razdoblje od 2019. do 2021. godine za šifru djelatnosti J62, pri čemu su podaci bili nekonsolidirane vrijednosti uz nazna-

ku vlasničke strukture. Vlasnička struktura obuhvaćala je status autonomnosti, zemlje središta nadređenog matičnog društva, oznake vlasništva, podrijetlo kapitala te broj zaposlenih prema satima rada u tekućoj i prethodnoj godini. Prilikom odabira usporednih podataka, OECD-ove Smjernice odobravaju usporedbu na razini nekoliko godina, kao i prosjeka nekoliko godina s krajnjim ciljem dobivanja kvalitetnijih podataka vezanih uz usporedne transakcije (OECD, 2022, str. 169-170).

4.2. OBLIKOVANJE UZORKA I OPERACIONALIZACIJA PODATAKA

U sklopu istraživanja prikupljeni su podaci poduzeća koja su kumulativno ispunjavala sljedeće kriterije. Prvo, obuhvaćena su poduzeća, koja imaju registriranu, kao primarnu djelatnost, oznaku J62 – *Računalno programiranje, savjetovanje i djelatnosti povezane s njima*. Grupa J62 obuhvaća šifre: 62.01 – *Računalno programiranje*; 62.02 – *Savjetovanje u vezi s računalima*; 62.03 – *Upravljanje računalnom opremom i sustavima* te 62.09 – *Ostale uslužne djelatnosti u vezi s informacijskom tehnologijom i računalima*. Potom, poduzeća koja su u 2021. godini ostvarila prihode veće od 7,5 milijuna HRK.

Sukladno činjenici kako se dio poduzeća koja su registrirana u ovoj šifri djelatnosti ujedno bavi i prodajom IT opreme, u cilju utvrđivanja poduzeća čija osnovna djelatnost nije vezana uz računalno programiranje već prodaju IT opreme, izračunat je pokazatelj udjela zaliha na svaki dan bilance u odnosu na ostvarene prihode. Poduzeća čiji je prosječni 3-godišnji udio zaliha u odnosu na ostvarene prihode od prodaje iznosio više od 5 % tretirana su kao trgovci IT opremom (Mitra i Chaya, 1996; Osadchij i dr., 2016, Lown i dr., 2000). Razlog zbog kojega je odabran 3-godišnji prosjek počiva na činjenici kako se dio poduzeća krajem 2020. godine, uslijed problema u lancima opskrbe, odlučio za nabavke zaliha potrebnih za vlastito funkcioniranje poslovanja (npr. zalihe opreme uslijed nemogućnosti nabavke specijalizirane IT opreme) ili prodaju ovih zaliha kroz ugovore o redovnom održavanju. Uslijed navedenoga dio promatranih poduzeća je upravo na financijskim izvještajima za 2020. godinu imao iskazan veći udio zaliha u odnosu na ovih 5 %, ali isti su vrlo vjerojatno rezultat problema s dobavnim lancima uzrokovanih pandemijom bolesti COVID-19.

Tablica 2. Pregled broja poduzeća po godinama i kategorijama

Vlasnička struktura poduzeća	2019.	2020.	2021.
Tuzemni rezidenti – TR	174	176	178
Tuzemni nerezidenti – TnR	84	89	91
Poduzeća koja su tijekom promatranog razdoblja iz domaćeg vlasništva prešla u strano vlasništvo – Prijelaz	10	11	11

Izvor: autori izračuni

Ukupno je u odabranom uzorku utvrđeno 329 poduzeća koja zadovoljavaju postavljene kriterije. Broj poduzeća uključenih u analizu ima sljedeću strukturu: (i) poduzeća u domaćem vlasništvu – 178, (ii) poduzeća u stranome vlasništvu – 91, (iii) poduzeća koja su tijekom promatranog razdoblja iz domaćeg vlasništva prešla u strano vlasništvo – 11, (iv) poduzeća u likvidaciji – 1 te (v) trgovci IT opreme – 48 poduzeća. Daljnje analize provedene su isključivo za prve tri kategorije poduzeća (i – iii), dok su iz analize isključena poduzeća u likvidaciji te poduzeća koja imaju prosječno više od 5 % zaliha u odnosu na ostvarene prihode u promatranom trogodišnjem razdoblju. U konačnici, pregled broja poduzeća po pojedinim godinama i kategorijama dan je Tablicom 2. Različit broj podataka po godinama rezultat je pojedinih poduzeća koja su započela poslovanje u nekoj od prethodnih godina, uslijed čega je zabilježeno blago povećanje broja ulaznih vrijednosti.

4.3. OPIS ISTRAŽIVAČKIH VARIJABLI

Za operacionalizaciju postavljenih hipoteza upotrijebljene su određene varijable. Postotak poreznog opterećenja računat je tako da se ukupan trošak poreza na dobit usporedio s ukupno ostvarenim prihodima tekućeg razdoblja. Opisana varijabla korištena je kako bi se analiziralo prosječno porezno opterećenje rezidenata i nerezidenata. Početna pretpostavka zasniva se na mišljenju kako je manja porezna opterećenost nerezidenata, kao rezultat manje EBIT marže i postotka bruto dobitka, što može upućivati kako nerezidenti nisu imali uvećanja osnovice poreza na dobit u kontekstu transfernih cijena.

Preostale varijable definiraju profitabilnost. Postotak bruto dobitka uzima u obzir ukupnu aktivnost poduzeća uz pretpostavku kako će bruto dobitak biti veći kod rezidenata. Stupanj vlastitog financiranja upućuje u kojoj mjeri se poduzeća financiraju iz vlastitih izvora naspram vanjskih izvora zaduživanja. Za očekivati je kako uz manju profitabilnost poslovanja i nezainteresiranost inozemnih vlasnika za dugoročnim prosperitetom poslovanja na jednoj lokaciji,

posebice ako postoji mogućnost smanjenja troškova na drugoj lokaciji, nerezidenti će ostvariti manji stupanj financiranja od rezidenata. Što je veća vrijednost varijable to je manje financiranje polugom, s time kako izvor poluge nerezidenata ima izravne učinke poreznog štita jer se kamate tretiraju kao rashod, što posljedično smanjuje poreznu osnovu i dobit, ali povećava ROS.

Standardizirani ROS i Berry omjer pokazatelji su za usporedbu transfernih cijena kod testiranja zadovoljavajuće dobiti utvrđujući visinu tržišne marže. Novikovas (2013, str. 146) opisuje Berry omjer kao pokazatelj dobiti poduzeća u određenom vremenskom razdoblju, pri čemu vrijednost 1 ili više pokazuje kako poduzeće ostvaruje dobit iznad svih varijabilnih troškova, *ceteris paribus*, usporedbom bruto dobiti i poslovnih rashoda. Varijabla % poslovnog dobitka ili ROS ključni je procjenitelj marže operativne dobiti prikazujući omjer EBIT i poslovnih prihoda. EBITDA kod transfernih cijena eliminira amortizaciju za analizu profitabilnosti te prema Rajin i Radojević (2016, str. 361) učinke financijskih i računovodstvenih odluka. Početna pretpostavka zasniva se na činjenici kako je EBITDA marža manja kod poduzeća koja prebacuju dobit, što signalizira neučinkovitost poslovanja ili seljenje dobiti posebno kod nerezidenata. Novikovas (2013, str. 147) navodi kako OECD-ove Smjernice nigdje izrijekom ne navode da Berry vrijednost ujedno označava primjenu TNMM metode, iako se navedeno uređuje u pojedinim nacionalnim pravilima. Međutim, većina stručnjaka za transferne cijene slaže se kako je Berry omjer, zapravo, varijacija C+ metode.

4.4. REZULTATI ANALIZE

4.4.1. REZULTATI ANALIZE ZA PRVU HIPOTEZU

Sa stajališta upravljanja transfernim cijenama za poreznu upravu ključno je utvrditi plaćaju li poduzeća iz IT sektora u stranom vlasništvu približno identične porezne stope kao i poduzeća u domaćem vlasništvu. Stoga je Tablicom 3. dan pregled ukupne pozicije poreza na dobit po promatranim strukturama vlasništva kao kumulativne godišnje RDG vrijednosti. Analizirajući ukupnu poziciju poreza na dobit proizlazi kako je porezno opterećenje rezidenata veće od poduzeća u inozemnom vlasništvu.

Tablica 3. Pregled pozicije poreza na dobit u RDG-u promatranih poduzeća

Vlasnička struktura poduzeća	2019.	2020.	2021.	Ukupno
Tuzemni rezidenti – TR	97.365.027	109.973.085	150.015.758	357.353.870
Tuzemni nerezidenti – TnR	36.391.218	30.901.355	54.064.502	121.357.075
Poduzeća koja su tijekom promatranog razdoblja iz domaćeg vlasništva prešla u strano vlasništvo – Prijelaz	8.962.293	4.320.551	–222.265	13.060.579
Ukupno	142.718.538	145.194.991	203.857.995	491.771.524

Izvor: autori izračuni

Kako apsolutna vrijednost ne mora nužno značiti i veću relativnu vrijednost za potrebe analize utvrđeno je prosječno porezno opterećenje omjerom poreza na dobit i ukupno ostvarenih prihoda pojedinih poduzeća kako je prikazano Tablicom 4. Dodatni izračuni upućuju na to da IT rezidenti imaju veće porezno opterećenje u odnosu na IT poduzeća u inozemnom vlasništvu, iako je stopa poreza na dobit ista. Prema tome, ne bi trebalo biti većih i značajnijih razlika između promatranih poduzeća u smislu poreznog opterećenja. Navedeno upućuje na to da bi svrsishodno bilo provesti detaljnije analize usporednosti ostvarenog dobitka poduzeća iz IT sektora u domaćem vlasništvu u odnosu na poduzeća u inozemnom vlasništvu. Pri tome, ključno je navesti kako su IT nerezidenti u prosjeku ostvarivali 47,17 % poslovnih prihoda iz transakcija s povezanim poduzećima.

Tablica 4. Izračun prosječnog poreznog opterećenja poduzeća u ovisnosti o vlasničkoj strukturi

Vlasnička struktura poduzeća	Godina			
	Prosječno porezno opterećenje u %			
	2019.	2020.	2021.	Mean
Tuzemni rezidenti – TR	2,85	2,69	2,98	2,84
Tuzemni nerezidenti – TnR	–1,71	–1,69	1,93	–0,45
Poduzeća koja su tijekom promatranog razdoblja iz domaćeg vlasništva prešla u strano vlasništvo – Prijelaz	4,60	2,19	1,51	2,71

Izvor: autori izračuni

Predmetno je utvrđeno stavljajući u omjer poslovne prihode iz odnosa s povezanim osobama u odnosu na ukupno ostvarene poslovne prihode na temelju prikupljenih podataka u konačnom uzorku. Složenije regresijske analize mogle

bi pokazati kako u nekim situacijama IT poduzetnici u inozemnom vlasništvu rade pomoćne poslove za vlasnika, pri čemu koriste hrvatske programere samo za programiranje segmenata, a ne za izradu cjelovitog softvera. U tom slučaju primjenjuje se C+ model, čime nedvojbeno manje poreza na dobit ostaje državnom proračunu jer su porezni nerezidenti „kooperanti“ koji rade po napucima inozemnog nalogodavca. S druge strane, navedeno može upućivati na to da inozemna društva, zapravo, zapošljavaju radnu snagu osnivanjem društva kćeri u Hrvatskoj te prodaju i naplaćaju svoje usluge društvima maticama u reverzibilnom procesu što ne slijedi u potpunosti Hyde-Choe model (2005).

Problem, općenito, manjih inozemnih investicija leži u činjenici administrativne prirode, čime se često birokratski opterećuje brzorastuća grana industrije. Bez obzira na niže porezno opterećenje, spora i glomazna administracija nije poticajna za otvaranje novih poduzeća i inozemna ulaganja. Može se složiti s tvrdnjom kako pretjerana regulacija transfernih cijena dovodi do prekomjernog fakturiranja, pada proizvodnje između vertikalno povezanih poduzeća i prebacivanja dobiti lažnim prikazivanjem transfera unutar poduzeća, kako tvrdi Landy (2006, str. 17), što upućuje na to da transferne cijene treba postaviti iznad graničnog troška proizvodnje. Nadalje, od 2022. godine postoje digitalni nomadi kao posebna kategorija fizičkih osoba, koji nisu hrvatski porezni rezidenti, ali rade za inozemnog nalogodavca s tuzemnom rezidentnošću. Ako takve fizičke osobe imaju status digitalnog nomada potpuno su oslobođene plaćanja poreza na dohodak te učinak nije vidljiv neposredno kroz transferne cijene zbog izostanka tuzemnog društva kćeri. U osnovi, radnik-digitalni nomad izravno ugovara poslove za inozemno IT društvo čime zaobilazi sve službene statistike, a obračunski podatci nisu vidljivi ni u poreznim evidencijama.

Opravljanje za ovakvu situaciju proizlazi iz činjenice kako je u Hrvatskoj lakše pronaći radnu snagu nego u matičnim državama zbog manjih plaća i nižih troškova rada, *ceteris paribus*. Ako bi se ista radna snaga zaposlila u državi matici, obveze poput preseljenja, smještaja i prosječne plaće zasigurno bi poslodavcu povećale operativne troškove rada. Stoga, inozemna društva nastoje radnike pronaći i zaposliti domicilno osiguravajući niže troškove. Međutim, nerezidentna IT društva i nadalje kupcima zaračunavaju usluge iz inozemnih matica jer kupci usluga vjerojatno ne bi pristali platiti isti iznos naknade rezidentnom društvu. Stoga je *modus operandi* vrlo jasan – (i) rezidentno IT društvo iz Hrvatske stvarno radi posao, (ii) prodaje uslugu naručitelju kao društvu matici u Austriji koja (iii) samo preprodaje uslugu poznatom kupcu iz Portugala i tako (iv) ostvaruje veću maržu zbog nižih troškova, čime se potvrđuje prva hipoteza.

4.4.2. REZULTATI ANALIZE ZA DRUGU HIPOTEZU

Značajno manja profitabilnost tijekom duljeg razdoblja može imati utjecaj i na stupanj vlastitog financiranja. Ako se stabilnost poslovanja analizira primjenom stupnja vlastitog financiranja dolazi se do podataka kako je veći odnos vlastitog financiranja kod rezidenata u odnosu na poduzeća u inozemnom vlasništvu, što nedvojbeno ukazuje na razlike u poslovnim modelima i načinu financiranja dviju vlasničkih struktura. Navedeno rezultira smanjenjem profitabilnosti i manjim interesom vlasnika u inozemnom vlasništvu jer se stabilnost poslovanja može kontrolirati davanjem zajmova od strane vlasnika. S takve osnove domaća poduzeća imaju više za izgubiti od inozemnih vlasnika jer inozemni udjeličari odobravaju zajmove i obračunavaju kamate koji su, domicilno, rashod, a dio dobiti transferiraju u inozemstvo (Eriotis i dr., 2021, str. 54).

Ipak, s aspekta stabilnosti poslovanja, stupanj vlastitog financiranja može biti jedan od elemenata analize stabilnosti poslovanja kao ključnog čimbenika u segmentu dugoročnog zadržavanja poslovne aktivnosti u nekoj od zemalja. Pod pretpostavkom „kooperantskog modela“, gdje IT poduzeća u inozemnom vlasništvu pružaju samo izabrani set usluga, uobičajeno programiranje, inozemnom vlasniku/grupi, ne postoji značajnija povezanost s pojedinom zemljom/zaposlenicima. Osnovni uvjet za zadržavanje aktivnosti odnosi se na cjenovnu pristupačnost, uključujući trošak radne snage. Zbog toga, porastom prosječne plaće, a što je iznimno zamjetno posljednje tri godine u IT sektoru – globalno, postoji rizik kako domaća radna snaga više nije cjenovno prihvatljiva inozemnom vlasniku, uslijed čega strani nalogodavac nema interes osiguravati značajniji iznos kapitala za potrebe vlastitog financiranja.

Prilikom definiranja visine opravdanosti transfernih cijena u pravilu se izračunavaju interkvartilni rasponi. Pri tome se podaci između minimuma i prvog kvartila te podaci između trećeg kvartila i maksimuma izbacuju iz analiza kao izuzeci. Stoga se za potrebe analize usporedivosti poslovanja uzimaju podaci između prvog i trećeg kvartila. Na temelju analiziranih podataka dolazi se do iznosa interkvartilnih raspona po pojedinim godinama u ovisnosti o vlasništvu poduzeća, što je prikazano Tablicom 5.

Tablica 5. Interkvartilni rasponi istraživačkih varijabli (u %)

Varijabla	Vlasnička struktura	Godina	Minimum	Q1	Medijan	Q3	Maximum	Raspon
ROS	TR	2019.	-439,2	4,40	13,40	25,12	94,73	5,72
		2020.	-109,86	5,72	14,31	26,16	93,51	4,57
		2021.	-37,72	5,28	15,47	27,13	94,91	5,14
		Prosjek	-439,2	5,11	14,19	25,79	94,91	5,05
	TnR	2019.	-27.142,50	2,21	5,86	8,97	57,30	4,07
		2020.	-2.351.527,71	2,41	6,02	10,68	52,77	4,43
		2021.	-15,64	1,84	6,65	14,03	74,53	7,62
		Prosjek	-2.351.527,71	2,12	6,19	11,70	74,53	5,53
	Prijelaz	2019.	7,57	9,90	28,48	48,15	50,12	4,86
		2020.	-24,18	4,61	17,76	30,42	48,72	6,61
		2021.	-14,28	2,84	8,40	24,55	38,35	8,65
		Prosjek	-24,18	4,94	20,39	33,15	50,12	6,71
	Industrija	ΣProsjek	2.351.527,71	3,61	10,45	22,54	94,91	6,25
Stupanj vlastitog financiranja	TR	2019.	-304,73	38,20	60,62	75,80	97,41	1,98
		2020.	-279,67	41,03	64,10	80,73	98,66	1,97
		2021.	-670,44	41,16	63,99	82,06	98,18	1,99
		Prosjek	-670,44	40,69	63,58	79,90	98,66	1,96
	TnR	2019.	-500,23	15,42	38,28	67,32	97,13	4,37
		2020.	-618,58	20,07	43,11	63,76	94,11	3,18
		2021.	-264,43	27,49	51,55	69,54	90,94	2,53
		Prosjek	-618,58	22,28	44,74	67,56	97,13	3,03
	Prijelaz	2019.	22,38	37,68	62,61	79,34	90,92	2,11
		2020.	-6,27	37,66	61,78	83,80	93,11	2,22
		2021.	17,4	44,35	62,18	84,02	90,23	1,89
		Prosjek	-6,27	39,21	62,25	83,11	93,11	2,12
	Industrija	ΣProsjek	-670,44	34,70	57,87	77,12	98,66	2,22
% poreznog opterećenja	TR	2019.	-3,42	0,55	2,09	4,24	17,23	7,76
		2020.	-0,10	0,58	2,11	4,12	17,03	7,07
		2021.	0,00	0,64	2,12	4,17	17,18	6,56
		Prosjek	-3,42	0,60	2,10	4,15	17,23	6,93
	TnR	2019.	-262,78	0,36	1,01	1,52	10,37	4,18
		2020.	-262,49	0,15	0,67	1,54	8,96	10,41
		2021.	-1,19	0,31	1,17	2,51	11,63	7,98
		Prosjek	-262,78	0,30	0,96	1,94	11,63	6,48
	Prijelaz	2019.	1,09	1,34	4,77	7,92	9,11	5,92
		2020.	-6,30	0,36	1,26	5,37	7,80	14,96
		2021.	-8,62	0,43	1,60	4,01	7,28	9,37
		Prosjek	-8,62	0,48	1,85	5,34	9,11	11,18
	Industrija	ΣProsjek	-262,78	0,30	0,96	1,94	11,63	6,48

% bruto dobiti	TR	2019.	-441	4,24	13,59	25,18	94,73	5,94
		2020.	-113,66	5,67	14,63	26,39	93,50	4,66
		2021.	-38,48	5,17	15,32	27,41	94,87	5,31
		Prosjek	-441	5,08	14,31	26,35	94,87	5,19
	TnR	2019.	-2.188,95	1,90	5,71	8,36	56,97	4,4
		2020.	-2.188,03	1,53	5,26	10,12	52,35	6,6
		2021.	15,9	1,69	6,88	13,65	73,94	8,09
		Prosjek	-2.188,95	1,74	5,68	11,58	73,94	6,68
	Prijelaz	2019.	7,08	9,90	28,72	48,04	50,54	4,85
		2020.	-24,4	3,08	17,75	29,89	43,29	9,7
		2021.	14,21	2,54	8,29	23,33	40,31	9,19
		Prosjek	-24,4	4,55	19,83	32,85	50,54	7,23
	Industrija	ΣProsjek	-2.188,95	3,48	10,30	15,31	94,87	4,40
EBITDA	TR	2019.	-439,2	7,54	16,16	29,07	95,41	3,86
		2020.	-28.765,85	8,52	19,36	30,94	95,08	3,63
		2021.	-37,31	8,90	19,76	32,03	98,85	3,6
		Prosjek	-28.765,85	8,48	18,83	30,50	95,85	3,59
	TnR	2019.	-26.864,26	3,98	8,23	11,68	58,20	2,93
		2020.	-2.336.909,64	3,58	8,57	15,68	53,21	4,38
		2021.	-14,58	3,77	9,53	18,62	74,72	4,94
		Prosjek	-2.336.909,64	3,82	8,74	15,49	74,72	4,05
	Prijelaz	2019.	8,06	10,97	30,09	49,57	54,66	4,52
		2020.	1,04	4,80	18,47	33,39	49,63	6,96
		2021.	-12,85	3,17	12,18	34,41	39,40	10,87
		Prosjek	-12,85	6,74	21,84	37,08	54,66	5,51
	Industrija	ΣProsjek	-2.336,91	6,28	14,22	19,80	98,85	3,15
Berry ratio	TR	2019.	-81,79	4,44	15,77	33,78	1.799,32	7,62
		2020.	-53,32	6,13	16,79	35,91	1.441,76	5,86
		2021.	-28,00	5,46	18,21	37,92	1.866,96	6,94
		Prosjek	-81,79	5,42	16,64	35,95	1.866,96	6,63
	TnR	2019.	-103,86	1,95	6,12	9,30	133,44	4,77
		2020.	-97,33	1,66	5,79	11,42	111,07	6,89
		2021.	-13,77	1,75	7,44	16,19	290,87	9,24
		Prosjek	-103,86	1,81	6,12	13,17	290,87	7,29
	Prijelaz	2019.	7,67	11,07	40,52	94,10	102,39	8,50
		2020.	-19,70	3,25	21,98	43,06	85,68	13,25
		2021.	-12,54	2,63	9,06	30,94	70,90	11,78
		Prosjek	-19,70	4,48	25,23	49,19	102,39	10,16
	Industrija	ΣProsjek	-103,86	3,64	11,57	29,27	1.866,96	8,04

ROA	TR	2019.	-135,35	6,18	18,94	39,27	113,31	6,35
		2020.	-169,24	8,94	20,56	39,05	95,61	4,37
		2021.	-646,45	8,24	19,97	41,32	243,16	5,01
		Prosjek	-646,45	7,39	20,04	39,25	243,16	5,31
	TnR	2019.	-192,36	3,76	9,23	19,54	87,31	5,19
		2020.	-190,83	3,10	9,18	20,39	85,60	6,58
		2021.	-23,73	3,96	14,09	25,77	408,71	6,50
		Prosjek	-192,36	3,76	11,39	21,96	408,71	5,84
	Prijelaz	2019.	17,15	23,96	35,47	52,73	61,80	2,20
		2020.	-32,19	16,81	34,74	44,41	53,99	2,64
		2021.	-6,00	7,43	14,55	37,26	54,35	5,01
		Prosjek	-32,19	15,12	29,75	38,75	61,80	2,56
Industrija ΣProsjek		-646,46	6,06	16,55	34,81	408,71	5,75	

Izvor: autorovi izračuni

Iz pregleda interkvartilnih vrijednosti vidljivo je kako poduzeća u domaćem vlasništvu ostvaruju veću profitabilnost poslovanja u odnosu na poduzeća u stranom vlasništvu. Poduzeća u domaćem vlasništvu su prosječno, u razdoblju od 2019. do 2021. godine, ostvarivala usporedivu profitabilnost između 5,11 % i 25,79 % za razliku od poduzeća u stranom vlasništvu koja su u istom razdoblju ostvarivala usporedivu profitabilnost između 2,12 % i 11,70 %. Na temelju toga može se pretpostaviti kako društva u stranom vlasništvu plaćaju naknade matici u obliku *management fee* i *royalty* ili zaračunavaju svoje usluge (sate rada) po cijenama koje su niže od uobičajenih.

Posljedično, time ostvaruju manje prihode, odnosno imaju veće rashode, što dovodi do smanjenja profitabilnosti te može upućivati na prilagođavanje transfernih cijena i prebacivanje dobiti u društva matice. S time u vezi, proizlazi kako se transferne cijene mogu koristiti u cilju povećanja dobiti nakon oporezivanja ili kao porezna olakšica. Teoretski, ako je u državi matice stopa poreza na dobit veća nego u državi kćeri razumno bi bilo transferirati dobit u državu kćer (Hrvatska) kako bi podlijegala manjem poreznom opterećenju. Transferne cijene u kontekstu poreznih olakšica povezane su s ukupnim poreznim opterećenjem. Tako porezne olakšice za investicije dopuštaju umanjeње porezne obveze pa je od velikog značaja transferirati dobit u poreznu jurisdikciju ciljem iskorištenja nižeg poreznog opterećenja.

Rezultati analize upućuju na to da od ukupno 91 analiziranog poduzeća ne-rezidenata, njih čak 55 ima manji stupanj povrata na prodaju od trogodišnjeg prosječnog prvog kvartila tuzemnih rezidenata (5,11 %). Također, vidljivo je kako su usporedni rasponi iznimno visoki, čime se ostavlja poprilično mane-

varskog prostora u definiranju usporednih transfernih cijena odabirom primjerenih metoda. Na ovaj način, nerezidenti, čija je profitabilnost značajnije niža, mogu prilikom testiranja profitabilnosti adekvatnim odabirom metoda osigurati usporedivost rezultata.

Tablica 6. Pregled usporednih pokazatelja i interkvartilnog raspona između IT poduzeća SAD-a i Hrvatske

Pokazatelj	IT poduzeća SAD			IT poduzeća Hrvatska		
	Q1	Q3	Raspon	Q1	Q3	Raspon
ROS*	4,93	16,77	3,40	3,61	22,54	6,25
Berry omjer**	1,21	4,26	3,52	3,64	29,27	8,04
ROA	5,20	12,93	2,49	6,06	34,81	5,75

* ROS je za potrebe ove analize, sukladno OECD-ovim Smjernicama za transferne cijene, računat kao omjer poslovnog dobitka i prihoda od prodaje. Hughes (2020) koristi pokazatelj „mark-up on total costs - MUTC“ kao omjer poslovnog dobitka i poslovnih rashoda.

** Berry omjer se, također, na različite načine može utvrditi. U radu se koristi omjer dobiti prije oporezivanja i poslovnih rashoda. Hughes (2020) izračunava pokazatelj na identičan način. Iako postoje određena odstupanja u metodologiji izračuna, za potrebe ovog istraživanja, ključan je izračun raspona kroz omjer Q1 i Q3.

Izvor: autorovi izračuni

Toliko velika odstupanja jedna su od najvećih zamjerki u definiranju transfernih cijena u seriji usporednih pokazatelja za različite djelatnosti koje su dokumentirane Hughesovim pristupom (Durst, 2022). Usporedbom izračunatih kvartila te rasponom između prvog i trećeg kvartila za sve IT poduzetnike s istraživanjem Hughes (2020) dolazi se do međunarodno usporednih rezultata prikazanih Tablicom 6.

Iz navedenog je izračuna vidljivo kako su usporedni rasponi na bazi izabranih pokazatelja, a koji su uobičajeni prilikom definiranja transfernih cijena, značajnije veći u Hrvatskoj u odnosu na vrijednosti SAD-a. Navedeno upućuje na još veću mogućnost u manipulaciji izračuna transfernih cijena kod IT poduzeća u inozemnom vlasništvu, kao i većoj vjerojatnosti da će se samo kod manjeg broja poduzetnika utvrditi odstupanje od usporednih poduzetnika. Pod pretpostavkom manjih interkvartilnih raspona, bližih medijanu, postoji veća vjerojatnost da će veći dio IT poduzeća u inozemnom vlasništvu odstupati od usporednih poduzeća i time biti u obvezi uvećati osnovicu poreza na dobit. Stoga, izbor metode ovisi o identificiranim rizicima alociranim kroz raspored lanca stvaranja vrijednosti u transakcijama s povezanim osobama dovodeći do

neoborivog stava kako nije problem u dopuštenim metodama za obračun transfernih cijena već je pitanje koja se, ovisno o situaciji, može primijeniti. Pfeiffer i dr. (2011) naglašavaju važnost centraliziranog određivanja transfernih cijena prema standardnim troškovima ako se MNC *ex ante* suočava s neizvjesnošću niskih troškova. Primjerice, usporedive nekontrolirane cijene vjerojatno nisu primjenjive jer se, u pravilu, radi o *custom made* stvarima za koje nema cjenika sata/usluge kao kod nekih drugih uslužnih djelatnosti, dok metoda trgovačkih cijena nije primjenjiva ako je riječ o isporuci usluge kod domaćih IT poduzeća, ali je primjenjiva kod preprodavatelja – društva matice. Osim toga, metoda C+ relativno je jednostavna za korištenje jer su troškovi poznati i nastaju s nepovezanim stranama, a pritom dodavanje određene marže, zapravo, znači istraživanje primjerenog postotka, što je često arbitrarno određeno na nekoj prihvatljivoj razini, uvažavajući razmišljanja Sahay (2003). Uzgred rečeno, diskrecijskim politikama odabira metoda potiče se *ex post* učinkovita trgovina (Feinschreiber, 2004) u ovisnosti o distribuciji troškova.

5. ZAKLJUČAK

Provedeno istraživanje upućuje na to da IT poduzeća u domaćem vlasništvu trenutačno imaju veće porezno opterećenje porezom na dobit u odnosu na IT poduzeća u inozemnom vlasništvu. Iako bi na osnovi prosječnih pokazatelja bilo teško zaključiti postojanje opravdanog umanjenja osnovice poreza na dobit kod IT poduzeća u inozemnom vlasništvu u odnosu na osnovicu poreza na dobit kod IT poduzeća u domaćem vlasništvu, a uzrokovano činjenicom da možda IT poduzeća u inozemnom vlasništvu pružaju samo ograničeni segment usluga za potrebe inozemnih grupacija, ključno je ovdje navesti kako ovo istraživanje može biti pokazatelj za detaljnije analize na razini porezne uprave, a koje, u konačnici, mogu rezultirati i poreznim nadzorima u cilju utvrđivanja stvarne porezne osnovice i poreznog opterećenja IT poduzeća nerezidenata.

S druge strane, povoljnije porezno opterećenje ne smije se promatrati samo kroz stopu poreza na dobit čineći tako ograničavajući čimbenik primijenjenog metodološkog okvira. Porezno je opterećenje širi i kompleksniji pojam od porezne stope. Primjerice, ako porezno zakonodavstvo neke troškove tretira kao porezno nepriznate i dopušta kao porezno priznate rashode samo niže iznose amortizacije, zapravo će i uz nižu stopu poreza na dobit vrlo lako biti riječ o većem poreznom opterećenju. Stoga je puno bolja mjera efektivna stopa poreza na dobit, koju društva, obveznici Međunarodnih standarda financijskog

izvještavanja, objavljuju u sklopu svojih godišnjih financijskih izvještaja, što može predstavljati snažniju osnovu proširenja provedenog istraživanja. U cilju povećanja transparentnosti OECD-ove metodologije treba odvagati opravdanost proširenja postojećih interkvartilnih raspona posebno za ona društva koja aktivno primjenjuju načela agresivnijeg oporezivanja i strateškog poreznog planiranja.

U budućnosti je za pretpostaviti kako će globalizacijski učinak na IT industriju zasigurno ostaviti značajan trag u obliku većeg okrupnjavanja i stvaranja multinacionalnih kompanija s 500 i više zaposlenih otvarajući nove perspektive transfernih cijena. Činjenica je kako će većina IT poduzeća „odumrijeti“ redovnim tokom, jer derivirane poslovne jedinice, stavljanjem u korporativni okvir, usporavaju investicije ili jednostavno nestanu vođeni sporednim motivima, ponajprije, razinom zarade ili visinom plaće.

REFERENCE

1. Apriliasari, V. (2021) OECD/G20 Pillar Two: Is it a compatible and feasible solution? *Jurnal Pajak Indonesia (Indonesian Tax Review)*, Vol. 5, No. 2, str. 136-149.
2. Avi-Yonah, R. S., Clausing, K. A. i Durst, M. C. (2008) Allocating business profits for tax purposes: A proposal to adopt a formulary profit split. *Fla. Tax Rev.*, No. 9, 497.
3. Barančić, T. (2021) Preliminarna analiza poslovanja IT sektora za 2021. godinu. BUG, Dostupno na: <https://www.bug.hr/komentar/it-sektor-u-hrvatskoj-impresivan-rast-izvan-svih-ocekivanja-28290> [15. prosinca 2023.]
4. Bartelsman, E. J. i Beetsma, R. (2000) Why Pay More? Corporate Tax Avoidance through Transfer Pricing in OECD Countries, *Center for Economic Studies and ifo Institute (CESifo)*, Munich, Working Paper, No. 324.
5. Clausing, K. A. (2000) The impact of transfer pricing on intrafirm trade. International taxation and multinational activity (str. 173 – 200). University of Chicago Press.
6. Collier, R., Devereux, M. P. i Vella, J. (2021) *Comparing proposals to tax some profit in the market country*. University of Oxford, Saïd Business School, Centre for Business Taxation.
7. De Broe, L., Danon, R. i Chand, V. (2019) *Comments to Public Consultation Document: Global Anti-Base Erosion Proposal ("GloBE") - Pillar Two*. UNIL-Tax Policy Center & KU Leuven (Institute for Tax Law).
8. de Wilde, M. F. (2019) On the OECD's 'Unified Approach' As Frankenstein's Monster and a Dented Shape Sorter (November 3, 2019)
9. Durst, M. C. (2022) It's Time to Reform Transfer Pricing Benchmarking, *Tax Notes International*, Vol. 106, No. 10, str. 1271–1278.
10. Elitzur, R. i Mintz, J. (1996) Transfer pricing rules and corporate tax competition. *Journal of Public Economics*, Vol. 60, No. 3, str. 401–422.

11. Eriotis, N., Missiakoulis, S., Ntokas, I., Tzavaras, M., Vasiliou, D. i Thalassinou, E. (2021) Tax Avoidance and TP: A VECM Regression Model. *International Journal of Finance, Insurance and Risk Management*, Vol. 11, No. 1, str. 50–67.
12. Feinschreiber, R. (2004) *TP methods: An applications guide*. New York: Wiley.
13. Greil, E. i Greil, S. (2021) *Transfer Pricing - A Case-Based Approach*, NWB Verlag GmbH & Co. KG, Herne
14. Grubert, H. i Mutti, J. (1991) Taxes, tariffs and transfer pricing in multinational corporate decision making. *The Review of Economics and Statistics*, Vol. 73, No. 2, str. 285–293.
15. Hanappi, T. i González Cabral, A. C. (2020) The impact of the Pillar One and Pillar Two proposals on MNE's investment costs: An analysis using forward-looking effective tax rates. OECD Taxation Working Papers, No. 50, OECD Publishing, Paris
16. Hearson, M. (2020) Corporate Tax Negotiations at the OECD: What's at Stake for Developing Countries in 2020? Brighton BN1 9RE, UK: International Centre for Tax and Development at the Institute of Development Studies.
17. HGK. (2020) Analiza hrvatske IT industrije 2014.–2019., Zagreb, Dostupno na: <https://www.hgk.hr/documents/analiza-hrvatske-it-industrije-20142019-kb602bb6ffa49ca.pdf> [16. prosinca 2023.]
18. Higinbotham, H., Srinivasan, N. i Eden, L. (2021) Amount B: Facts and Circumstances Matter - Even for Routine Distributors. *Tax Management International Journal*, Vol. 50, No. 2, str. 90–97.
19. Hines, J. R. i Rice, E. M. (1994) Fiscal Paradise: Foreign Tax Havens and American Business. *The Quarterly Journal of Economics*, Vol. 109, No. 1, str. 149–182.
20. Horst, T. (1971) The Theory of the Multinational Firm: Optimal Behavior under Different Tariff and Tax Rates. *Journal of Political Economy*, Vol. 79, No. 5, str. 1059–1072.
21. Hrbić, R. i Grebenar, T. (2021) Procjena spremnosti hrvatskih poduzeća na uvođenje tehnologija I4.0., HNB: Zagreb. Dostupno na: <https://www.hnb.hr/documents/20182/3776564/i-062.pdf/5720fb3d-20b6-e592-bb2320cd61c19680> [16. prosinca 2023.]
22. Hughes, A. (2020) Transfer Pricing Benchmark: North American IT Services, *Tax Notes Int'l*. Dostupno na: www.taxnotes.com/featured-analysis/transfer-pricing-benchmark-2022-north-american-it-services/2022/11/11/7fc52 [16. prosinca 2023.]
23. Hyde, C. E. i Choe, C. (2005) Keeping Two Sets of Books: The Relationship between Tax and Incentive TP. *Journal of Economics & Management Strategy*, Vol. 14, No. 1, str. 165–86.
24. Kopun Grupa. Minimalna stopa poreza na dobit. 2. studenoga 2021. Dostupno na: <https://kopun.hr/> [16. prosinca 2023.]
25. Landy, F. (2006) Vertical Integrated Enterprises and Transfer Pricing, University of Helsinki, Discussion Paper No. 626.
26. Lohse (Zinn), T., Riedel, N. i Spengel, C. (2014) The increasing importance of transfer pricing regulations: a worldwide overview. *Intertax*, Vol. 42, No. 6/7.

27. Lown, C. S., Osler, C. L., Sufi, A. i Strahan, P. E. (2000) The changing landscape of the financial services industry: What lies ahead?. *FRB of New York Economic Policy Review*, Vol. 6, No. 4, str. 39–55.
28. Lubis, A. H. P. i Rahayu, N. (2021) Emphasizing Inter-Nation Equity in the New Digital Economy's Taxing Rights Allocation Scheme. *International Journal of Scientific and Research Publications*, Vol. 11, No. 7.
29. Marques, M. i Pinho, C. (2016) Is transfer pricing strictness deterring profit shifting within multinationals? Empirical evidence from Europe. *Accounting and Business Research*, Vol. 46, No. 7, str. 703–730.
30. Graetz, M. J. (2021) A Major Simplification of the OECD's Pillar 1 Proposal, *Tax Notes International*, January, 11.
31. Mitra, S., Chaya, A. K. (1996) Analyzing cost-effectiveness of organizations: the impact of information technology spending. *Journal of Management Information Systems*, Vol. 13, No. 2, str. 29–57.
32. Navarro, A. (2021) The Allocation of Taxing Rights under Pillar One of the OECD Proposal (November 9, 2021). *OUP Handbook of International Tax Law* (F. Haase, G. Kofler eds., Oxford University Press 2021 Forthcoming)
33. Novikovas, M. (2013) Evaluation of Berry ratio reliability determining transfer pricing, *Przedsiębiorstwo i Finanse* No. 3, Wyższa Szkoła Finansów i Zarządzania w Białymstoku, Białystok, str. 141–152.
34. OECD. (2020) Tax Challenges Arising from Digitalisation – Economic Impact Assessment: Inclusive Framework on BEPS, OECD/G20 Base Erosion and Profit Shifting Project, Dostupno na: <https://www.oecd.org/tax/beps/tax-challenges-arising-from-digitalisation-economic-impact-assessment-0e3cc2d4en.htm> [16. prosinca 2023.]
35. OECD. (2022) Transfer Pricing Guidelines for MNE and Tax Administrations
36. OECD. (2022a) Pillar One – A Tax Certainty Framework for Amount A
37. OECD. (2022b) Progress Report on the Administration and Tax Certainty Aspects of Pillar I
38. Osadchiy, N., Gaur, V. i Seshadri, S. (2016). Systematic risk in supply chain networks. *Management Science*, Vol. 62, No. 6, str. 1755–1777.
39. Perčević, H. (2015) Usklađenost regulatornog okvira transfernih cijena u zemljama Europske unije. *Ekonomika misao i praksa*, 2, str. 627 – 650.
40. Perčević, H. (2022) Analiza učestalosti primjene prethodnih sporazuma o transfernim cijenama u zemljama EU. *Ekonomika misao i praksa*, Vol. 31, No. 1, str. 163–87.
41. Pfeiffer, T., Schiller, U. i Wagner, J. (2011) Cost-based transfer pricing. *Review of Accounting Studies*, Vol. 16, str. 219–246.
42. Rajin, D. i Radojević, T. (2016) The Application of Transfer Pricing Between Related Parties. U *Sinteza 2016-International Scientific Conference on ICT and E-Business Related Research*, Singidunum University, str. 359–363.
43. Riccardi, A. (2021) Implementing a (global?) minimum corporate income tax: an assessment of the so-called” Pillar Two” from the perspective of developing countries. *Nordic Journal on Law and Society*, Vol. 4, No. 1, str. 1–38.

44. Sahay, S. A. (2003) Transfer pricing based on actual cost. *Journal of Management Accounting Research*, Vol. 15, str. 177–192.
45. Schjelderup, G. i Weichenrieder, A. J. (1999) Trade, multinationals, and transfer pricing regulations. *Canadian Journal of Economics*, str. 817–834.
46. Sikka, P. i Willmott, H. (2010) The dark side of transfer pricing: Its role in tax avoidance and wealth retentiveness. *Critical perspectives on accounting*, Vol. 21, No. 4, str. 342–356.
47. Sopta, M., Bilas, V. i Jakupović, S. (2021) Analysis of the compliance of the regulatory framework of transfer pricing in the countries of the European union. *Economic and Social Development: Book of Proceedings*, str. 137–148.
48. Stewart, J. C. (1989) Transfer pricing: some empirical evidence from Ireland. *Journal of Economic Studies*, Vol. 16, No. 3.
49. Treidler, O. (2020) *Transfer Pricing in One Lesson - A Practical Guide to Applying the Arm's Length Principle in Intercompany Transactions*, Springer.
50. Vicard, V. (2015) Profit shifting through transfer pricing: evidence from French firm level trade data. Working papers No. 555, Banque de France.
51. Wardell-Burrows, H. (2023) Pillar Two and Developing Countries: The STTR and GloBE Implementation. *Intertax*, Vol. 51, No. 2, str. 118–133.

DISCRETION AND FAIRNESS IN CONNECTION WITH TRANSFER PRICING

Full Professor Ivo Mijoć, PhD

Faculty of Economics in Osijek

Josip Juraj Strossmayer University in Osijek

e-mail: ivo.mijoc@efos.hr

Dubravka Kopun Jr., PhD

Kopun Group Zagreb

e-mail: dkopun@yahoo.com

Assistant Professor Ivan Čevizović, PhD

Čevizović j.t.d. Zagreb

e-mail: ivan.cevizovic@cevizovic.eu

ABSTRACT

The regulation of profits or prices based on the trend of marginal production costs and tax performance correlates with the internal policies of companies regarding import and export volumes, making transfer pricing a justified instrument of international trade. The aim of this paper is to analyze the level of tax burden and profitability in a sample of 280 IT companies over a three-year period by comparing Croatian companies with foreign-owned companies. The primary purpose is to define the differences between resident and non-resident taxpayers and to assess the performance of IT companies using the methodology described in the OECD Guidelines. By applying financial indicators and interquartile ranges, the results show that domestic residents face a higher tax burden compared to non-residents but achieve higher corporate profitability. This discrepancy raises the issue of discretion and fairness in transfer pricing, which is discussed in the paper, along with proposed solutions.

Key words: transfer pricing, OECD Guidelines, profitability, financial indicators, interquartile ranges

JEL classification: H25, H26, M40, M41



DIO 2: BANKARSTVO, KAPITALNI ZAHTEJEVI I ESG RIZICI

POSljedICE USKLAĐIVANJA S KAPITALNIM ZAHTJEVIMA – ZAŠTITA OD RIZIKA ILI OKIDAČ RIZIČNIJEG PONAŠANJA BANAKA?

prof. dr. sc. Ana Kundid Novokmet

Ekonomski fakultet, Sveučilište u Splitu

e-mail: ana.kundid.novokmet@efst.hr

SAŽETAK

Kapitalni zahtjevi nedvojbeno su najsnažnije uporište prudencijalne regulacije banaka u posljednjih 30 godina. Ustrajanje na ovom regulatornom konceptu duguje se njegovoj osnovnoj logici slobode izbora poslovnog modela, brzine rasta i razine rizika banke uz adekvatnu odgovornost njezinih vlasnika. Omogućavanjem slobode izbora poslovnog modela banke te tolerirajući različite sklonosti u preuzimanju ukupnih i pojedinačnih rizika u bankovnom poslovanju, ali unutar postavljenih granica minimalno zahtijevane odgovornosti bankovnih dioničara, nastojala se postići ravnoteža između deregulacijskih tendencija i cilja održavanja financijske stabilnosti. Kompleksnost i visoki troškovi usklađivanja s kapitalnim zahtjevima, njihove višestruke iteracije i dodatna propisivanja, s jedne strane, te propasti banaka i financijske krize, s druge strane, ne idu u prilog daljnjem inzistiranju na ovom regulatornom instrumentu. No, alternativna rješenja izostaju uglavnom zato što su ona koja se predlažu radikalna, isključiva i nedovoljno pomirena s ideologijom financijske liberalizacije. Stoga, kapitalni zahtjevi opstaju, usprkos konstantnim kritikama neučinkovitosti ili čak kontraproduktivnosti. Naime, kapitalni zahtjevi mogu potaknuti dodatno preuzimanje rizika banaka i time biti oprečni cilju sigurnosti i stabilnosti bankovnog poslovanja. Ovaj rad ima za cilj analizirati teorijska i empirijska uporišta promatranog fenomena te odgovoriti na pitanje jesu li kapitalni zahtjevi zaštita od rizika ili uzrok dodatnog preuzimanja rizika banaka.¹

Ključne riječi: *kapitalni zahtjevi, preuzimanje rizika, bankovna regulacija, teorija moralnog hazarda, teorija kapitala kao zaštite*

JEL klasifikacija: G21, G28

¹ Rad se temelji na doktorskoj disertaciji autorice, odnosno sljedećoj referenci: Kundid, A. (2013) *Primjerenost kapitalnih zahtjeva za stabilnost bankarskog sektora*. Doktorska disertacija. Ekonomski fakultet: Split.

1. UVOD

Osnovno obilježje dobro osmišljene regulative jest pokušaj predviđanja načina usklađivanja objekata regulacije s regulatornom mjerom te pravovremeno uviđanje potencijalnih nedorečenosti i manjkavosti u njezinu dizajnu, a koje otvaraju put ka regulatornom otporu i/ili regulatornoj arbitraži. Regulatorni otpor sinonim je za kreativno izbjegavanje regulatornog opterećenja, dok regulatorna arbitraža zahtijeva manje inovativan pristup i svodi se na iskorištavanje previda prilikom formuliranja regulatornih propisa ili pravila (Kundid, 2014). Neovisno o međusobnim razlikama, oba fenomena smanjuju učinkovitost regulative. Na koji se način banke usklađuju s kapitalnim zahtjevima, intrigantno je pitanje ekonomske teorije i prakse više od 30 godina. Osnovni cilj ovog rada jest dati uvid u ključne iskorake u teorijskim i empirijskim istraživanjima ne ulazeći u tehničke detalje promatrane regulatorne mjere i njezine postupne izmjene te fokusirajući se isključivo na efekte kapitalnih zahtjeva na strukturu bankovnog portfelja.

Kapitalni zahtjevi osmišljeni su radi stabilnosti i sigurnosti bankarskog sektora te stvaranja preduvjeta za lojalnu konkurenciju na globalnoj razini (Kundid Novokmet, 2015, str. 158). Temelje se na ujednačenoj definiciji i mjerenju kapitala te različitim mogućnostima procjene kontrolabilnih i nekontrolabilnih rizika banke za koje treba postojati adekvatna podrška u regulatornom kapitalu. Od kraja 1980-ih, kada su prvi put uvedeni, prošli su značajne izmjene. Posljednja je bila 2017. godine.

Više je načina na koji se banke mogu uskladiti s kapitalnim zahtjevima. Povećanje bankovnog – regulatornog ili jamstvenog kapitala moguće je putem emisija novih dionica, tj. efektivno povećanje kapitala, generiranja internog pozitivnog kapitala putem zadržanih zarada te emisija subordiniranog duga. Spajanjem potkapitaliziranih i visoko kapitaliziranih banaka također je moguće unaprijediti regulatorni kapital (Lastra, 2004, str. 230), no takva su rješenja, ipak, rjeđe zastupljena u praksi. Rizikom ponderirana aktiva može se smanjiti restrukturiranjem aktive prema manjim ponderima rizika, ograničenjem njezina rasta, prodajom ili sekuritizacijom dijela aktive te smanjenjem izvanbilančne evidencije. U obama slučajevima, tj. pozicija kapitala i rizika mogu se primijeniti i obrnute operacije.

Pored simultanih promjena u regulatornom kapitalu i rizikom ponderiranoj aktivi, bilo da se one događaju u kratkom ili, pak, dugom roku, moguće su i isključive usklade preko regulatornog kapitala (prilagodba na strani pasive) ili


rizika (prilagodba na strani aktive). S obzirom na to da je regulatorna mjera kapitalnih zahtjeva često osporavana dovođenjem u vezu s dodatnim preuzimanjem rizika u bankovnom poslovanju, u fokusu rada jest pregled literature o posljedicama kapitalnih zahtjeva za rizičnost bankovne aktive.

Indikativan prikaz kretanja pokazatelja adekvatnosti kapitala i neprihodonosnih kredita, kao mjere materijaliziranog kreditnog rizika, za države članice Europske unije, Ujedinjeno Kraljevstvo i SAD u razdoblju od 2007. do 2020. godine sugerira da odgovor na ovo pitanje nije jednoznačan, niti jednodimenzionalno određen (Grafikoni 1. i 2.). Naime, jednostavnim izračunom korelacije između promatranih varijabli dobiva se suprotni predznak za EU-27 ($r = 0,249$) u odnosu na Ujedinjeno Kraljevstvo ($r = -0,409$) i SAD ($r = -0,171$).

Iako prethodni rezultati nisu nikakva potvrda kauzalnosti, za očekivati je da i unutar bankarskih sektora postoje heterogeni obrasci u usklađivanju banaka s kapitalnim zahtjevima, ovisno o ciljanoj razini regulatornog kapitala, volatilnosti aktive, raspoloživom vremenu, tj. brzini potrebne prilagodbe te općim gospodarskim uvjetima. Primjerice, banke s niskom volatilnošću aktive i/ili mogućnošću brze prilagodbe mogu ciljati nisku razinu kapitaliziranosti (Mommel i Raupach, 2010). Mogućnost brze prilagodbe najčešće je adut velikih banaka, dok druge na to mogu računati samo u razdobljima obilja i cjenovne dostupnosti kapitala. Stoga, većina banaka obično drži veće razine kapitala od regulatorno zahtijevanih u cilju normalne funkcionalnosti i izbjegavanja intervencija regulatora. Može li takva praksa biti okidač za uvećano preuzimanje rizika i, ako da, znači li to da su kapitalni režimi kontraučinkoviti, raspravlja se u narednim poglavljima.


Drugo poglavlje sučeljava teoriju moralnog hazarda s teorijom kapitala kao zaštite putem pregleda najznačajnijih radova u ovom području, dok treće poglavlje daje uvid u metodološka obilježja i zaključke izabranih empirijskih radova o predmetnoj temi. Rad završava zaključnim razmatranjima.

Grafikon 1. Pokazatelj adekvatnosti kapitala (%), 2007. – 2020.



Izvor: izračun i izrada autorice na temelju podataka raspoloživih na: *World Development Indicators*, <https://databank.worldbank.org/source/world-development-indicators> [7. 12. 2023.]

Grafikon 2. Pokazatelj neprihodonosnih kredita u ukupnim kreditima (%), 2007. – 2020.



Izvor: izračun i izrada autorice na temelju podataka raspoloživih na: *World Development Indicators*, <https://databank.worldbank.org/source/world-development-indicators>, [7. 12. 2023.]

2. TEORIJSKA SUPROTSTAVLJANJA – KAPITAL KAO ZAŠTITA ILI IZVOR MORALNOG HAZARDA?

Teorija moralnog hazarda (engl. *moral hazard theory*) i teorija kapitala kao zaštite (engl. *capital buffer theory*, *precautionary regulatory capital theory*) najvažnija su teorijska uporišta u domeni utjecaja kapitalnih zahtjeva na preuzimanje rizika banaka, iako s međusobno oprečnim zaključcima. I dok teorija kapitala kao zaštite (Marcus, 1984; Calem i Rob, 1999; Milne i Whalley, 2001) opravdava upotrebu kapitalnih zahtjeva te promiče razboritost u ponašanju bankovnih menadžera, teorija moralnog hazarda (Koehn i Santomero, 1980; Kim i Santomero, 1988; Gennotte i Pyle, 1991; Rochet, 1992; Blum, 1999) kapitalne zahtjeve ocjenjuje kontraproduktivnima te dovodi u vezu s povećanom rizičnošću bankovnih aktiva i posljedično bankovnom nestabilnošću.

Promjene u sastavu bankovnog portfelja izazvane primjenom kapitalnih zahtjeva među prvim su teorijski analizirali Koehn i Santomero (1980) referirajući se na teoriju portfelja, preciznije model prosjek – varijanca. Iako su pretpostavili da se regulacijom kapitala ograničava isključivo financijska poluga, ali ne i sastav bankovne aktive, njihovo istraživanje afirmiralo je stav o tome da su kapitalni zahtjevi neadekvatna i kontraproduktivna regulatorna mjera za kontrolu bankovnih rizika i smanjenje vjerojatnosti njezine propasti. Smanjenjem dopuštene financijske poluge banke, granica efikasnosti ulaganja pomiče se ulijevo ($\frac{\partial \sigma_p^2}{\partial c} < 0$, $\frac{\partial E_p}{\partial c} < 0$, gdje su E_p i σ_p^2 očekivani prinos i varijanca prinosa po jedinici kapitala na bankovni portfelj, a $c \equiv \frac{K}{A}$ – ograničenje financijske poluge), što bankovni menadžeri kompenziraju promjenom strukture portfelja, odnosno izborom rizičnijih aktiva. Naime, ako je očekivani prinos po jedinici kapitala na bankovni portfelj (E_p) jednak $E_p = x_0 R + \sum_{i=1}^n x_i E_i$, pri čemu je x_0 postotak kapitala u negativnoj aktivni (depozitima) koji nosi bezrizičnu stopu R , a x_i postotak vrijednosti kapitala uložen u i -tu aktivu te E_i očekivani prinos na i -tu aktivu, tada ograničenje u prikupljanju depozita $x_0 \geq 1 - \frac{1}{c}$ smanjuje izvore koji nose bezrizičnu stopu zbog čega očekivani prinos na kapital pada. Kada regulacija kapitala djeluje isključivo na visinu financijske poluge, tada se povećanje potrebnog kapitala preusmjerava na aktivu x_i , koja može nositi jednake ili više stope prinosa E_i u odnosu na stope prinosa prije ograničenja financijske poluge. Ovisno o rizičnom profilu – koeficijentu averzije prema riziku, banke pod ovom regulatornom mjerom više ili manje povećavaju rizičnost aktiva kako bi se zadovoljio uvjet maksimiziranja korisnosti ulaganja. Za očekivati je da će banke koje već posjeduju više rizične aktive u prisutnosti ove regulatorne

mjere nastaviti taj trend u odnosu na konzervativne banke. Odnosno, smanjeni financijski rizik može biti kompenziran povećanom rizičnošću aktive zbog čega ograničenje financijske poluge može u konačnici povećati vjerojatnost propasti banke. Povećanje varijance (σ_p^2) povećava vjerojatnost propasti, dok je povećanje očekivanog prinosa (E_p) i povećanje kapitaliziranosti smanjuje. Koehn i Santomero (1980, str. 1243) zaključuju da će regulacijom kapitala sigurne banke postati sigurnije, a rizične institucije još rizičnije pa kao korisnija rješenja predlažu direktna ograničenja u strukturiranju bankovnog portfelja. Istog su razmišljanja bili Kim i Santomero (1988) u vremenima kada su definirani kapitalni zahtjevi u odnosu na rizikom ponderiranu aktivu. U slučaju da su rizični ponderi pravilno procijenjeni, smanjeni financijski rizik ne mora voditi ka povećanju rizičnosti aktive, ali kapitalni zahtjevi i dalje mogu uzrokovati značajne strukturne promjene u čitavoj financijskoj industriji, poput poskupljenja ili redukcije plasmana rizičnijih pondera, bilo da je ona uzrokovana ponudom ili potražnjom, te držanja prevelike likvidnosti (Kim i Santomero, 1988, str. 1230-1231).

Potpuno suprotno, Furlong i Keeley (1989) te Keeley i Furlong (1990) dokazali su da se povećanjem regulatorne kapitaliziranosti smanjuje inicijativa za preuzimanjem dodatnih rizika u bankovnom poslovanju, odnosno povećanje rizičnosti bankovnih aktiva (engl. *capital-at-risk effect*). Njihova polazna pretpostavka jest maksimiziranje tržišne vrijednosti uloga vlasnika. Ako je vrijednost banke V_0 predstavljena kao suma vrijednosti kapitala C_0 i vrijednosti osiguranih depozita I_0 , što podrazumijeva zaduženost banke iznad vlasničkog kapitala, banka može nastojati maksimizirati opcijsku vrijednost osiguranja depozita I_0 . Uz zadani kapital C_0 , ako je $V_0 = C_0 + I_0$, tada povećanje I_0 putem povećanja udjela financiranja osiguranim depozitima i povećanja rizičnosti ulaganja doprinosi rastu vrijednosti banke. Naime, sadašnja vrijednost opcije osiguranja depozita jednaka je $I_0 = \frac{D_0}{P} P_1 - \frac{C_0 + D_0}{P} P_1 [Sx_1 + (1-S)y_1]$, pri čemu je $(C_0 + D_0)/P$ broj jedinica ulaganja u vrijednosnice, a $P_1 [Sx_1 + (1-S)y_1]$ sadašnja vrijednost ulaganja u pojedinu vrijednosnicu, gdje je X rizičnija vrijednosnica (x je prinos na X) i Y manje rizična vrijednosnica (y je prinos na Y), a S njihovi udjeli, dok je $(D_0/P)P_1$ sadašnja vrijednost potraživanja deponenata. Opcijska vrijednost osiguranih depozita I_0 raste smanjenjem sadašnje vrijednosti ulaganja u vrijednosnice i/ili povećanjem sadašnje vrijednosti potraživanja osiguranih deponenata. Banka maksimizira vrijednost I_0 održavanjem najvećeg mogućeg stupnja financijske poluge i povećanjem rizičnosti ulaganja (do maksimalno $S = 1$). Pod pretpostavkom nepromijenjenog kapitala, ograničavanje financijske

poluge ograničava veličinu aktive i veličinu zaduživanja te banke neće imati inicijativu za povećanjem rizika zbog smanjenja graničnih dobitaka od povećanja rizičnosti aktive. Povećanjem uloga vlasnika također se smanjuje opcijska vrijednost osiguranih depozita zbog čega se smanjuje i sklonost povećanju rizičnih uloga potencijalno na uštrb sustava osiguranja depozita. Naime, smanjenje dijela osiguranih depozita zbog regulatornih zahtjeva smanjuje sadašnju vrijednost osiguranih depozita pa nema smisla dodatno je umanjivati rastom aktive i povećanjem njezine rizičnosti. Furlong i Keeley (1989) zaključuju da će usklađivanje banaka sa zahtjevima regulatornog kapitala prije ići u smjeru povećanja kapitala u odnosu na smanjenje duga ili prodaju aktive.

Osim toga, Keeley i Furlong (1990) kritiziraju uporabu pristupa prosjek – varijanca u analizi efekata kapitalnih zahtjeva na rizičnost aktive i rizik insolventnosti banaka koji je zastupljen u radovima Koehn i Santomero (1980) te Kim i Santomero (1988). Osnovna im je zamjerka ignoriranje opcijske vrijednosti koje donosi osiguranje depozita i pretpostavljanje konstantnih troškova financiranja banke nezavisnih od rizika portfelja ili rizika insolventnosti. U situaciji da banke nisu u sustavu osiguranja depozita, porastom rizika bankovnog poslovanja rast će i zahtijevana stopa prinosa od strane neosiguranih deponenata. U slučaju osiguranih banaka, očekivani neto marginalni troškovi depozita koji se sastoje od očekivane kamate i fiksne premije na osiguranje depozita padat će povećanjem zaduženosti banke s obzirom na to da se povećava opcijska vrijednost osiguranih depozita (Keeley i Furlong, 1990, str. 71-72). Povećanje zaduženosti smanjuje vrijednost novih i postojećih depozita s aspekta banke koja maksimizira tržišnu vrijednost. Stoga, u želji da povećaju opcijsku vrijednost osiguranih depozita, čak i riziku neskloni bankovni menadžeri mogu nastojati maksimizirati financijsku polugu i rizičnost aktive (Furlong i Keeley, 1987). Odnosno, dokazi o utjecaju regulacije kapitala na vjerojatnost bankrota banke zbog povećanja rizičnosti aktiva ne mogu biti utemeljeni ako se podrazumijevaju konstantni troškovi financiranja i linearan odnos zaduženosti banke te rizika i povrata. Ova pretpostavka implicira da je vjerojatnost propasti banke nula te da ne postoji sustav osiguranja depozita. Zaključno, Furlong i Keeley (1987, str. 32) ističu da je regulacija kapitala poželjna zato što se smanjuju potencijalna potraživanja banaka prema sustavu osiguranja depozita, jer banke s najmanje kapitala imaju najviše motiva za povećanje rizika aktive.

Navedeni radovi polaze od pretpostavke da je bankovna aktiva sastavljena od utrživih vrijednosnica čija je neto sadašnja vrijednost jednaka nuli. Za razliku od toga, Gennotte i Pyle (1991) u razmatranje uzimaju kredite kao najznačaj-

niju komponentu bankovne aktive te zaključuju da postojanje sustava osiguranja depozita, jednako kao i restriktivnija regulacija kapitala vode prema izboru neefikasnih plasmana te povećanju rizičnosti aktive, što povećava vjerojatnost propasti banke. Naime, u slučaju nepostojanja sustava osiguranja depozita banke su indiferentne između financiranja investicija kapitalom ili depozitima te nastoje maksimizirati neto sadašnju vrijednost svog portfelja (Gennotte i Pyle, 1991, str. 807). Ako sustav osiguranja depozita ipak postoji, neto sadašnja vrijednost banke rastuća je funkcija iznosa osiguranih depozita zbog opcijske vrijednosti osiguranih depozita. Neto sadašnja vrijednost banke tada je zbroj neto sadašnje vrijednosti aktive i vrijednosti osiguranih depozita. Uz pretpostavku da je vjerojatnost bankrota banke pozitivna, supstitucija bankovnog kapitala osiguranim depozitima povećava vrijednost banke. Banke mogu povećavati rizičnost aktive sve dok vrijednost dodatne jedinice osiguranja depozita kompenzira negativnu sadašnju vrijednost dodatne jedinice rizičnije investicije (Gennotte i Pyle, 1991, str. 811) kojoj značajno doprinose troškovi odobravanja kredita (prikupljanja informacija i samog ugovaranja). Zato osiguranje depozita stvara preduvjete za neefikasne investicije i neefikasno preuzimanje rizika. Ograničavanje financijske poluge i rizika banaka od strane regulatora nedostavno je za eliminiranje koristi stvorenih sustavom osiguranja depozita s obzirom na informacijske prednosti banaka u odnosu na regulatore. Restrikcija financijske poluge smanjuje vrijednost osiguranja depozita, a istovremeno može uzrokovati izmjenu strukture aktive prema većoj rizičnosti uz njezinu nepromijenjenu ili smanjenu veličinu. Stoga, Gennotte i Pyle (1991) poručuju da se uvođenjem kapitalnih zahtjeva ne mora smanjiti vjerojatnost bankrota banke jer povećanje kapitaliziranosti ne može zamijeniti dobro nadgledanje rizičnosti aktiva od strane regulatora.

Nastavno na prethodno, Rochet (1992) potvrđuje da fiksne premije osiguranja depozita mogu dovesti do neželjenih učinaka od postojanja sustava osiguranja depozita jer ograničena odgovornost vlasnika bankovnog kapitala može ići u smjeru maksimalnog iskorištavanja eksplicite danih državnih garancija za depozite ulaganjem u pretjerano rizične aktive. Uzimajući u razmatranje banku koja maksimizira tržišnu vrijednost, Rochet (1992) također zaključuje da regulacija kapitala ne može spriječiti banke da izabiru vrlo rizične portfelje, dok se neželjene posljedice sustava osiguranja depozita mogu spriječiti uvođenjem premija za osiguranje depozita koje će biti osjetljive na rizik banke. U prisutnosti diferenciranih premija i sama regulacija kapitala bila bi suvišna. Odnosno, kontrola kapitala imala bi smisla samo ako diferencijacija premija za osiguranje depozita ne bi postojala, a rizični ponderi kod kapitalnih zahtjeva bili

pravilno ocijenjeni i znatno šireg spektra rizika od isključivo kreditnog rizika. Stoga, Rochet (1992) predlaže uvođenje tzv. tržišno utemeljenih rizičnih pondera, odnosno tržišnih beta za aktive kao smjernicu za njihovo određivanje. Naime, rizični ponderi trebaju biti proporcionalni sustavnom riziku aktiva da bi se vjerojatnost bankovne propasti smanjila. U konačnici, autor ne osporava sklonost moralnom hazardu nedovoljno kapitaliziranih banaka te zagovara simultano djelovanje konzistentnih prudencijalnih mjera.

Opisana istraživanja dokazuju ili osporavaju pozitivan utjecaj kapitalnih zahtjeva na izbor rizičnije strukture bankovnog portfelja, odnosno pojavu moralnog hazarda bankovnih dioničara stavljaju u kontekst kontrole kapitala. Umjesto moralnog hazarda izazvanog izmjenom rizične strukture portfelja (engl. *asset-substitution moral hazard*), Besanko i Kanatas (1996, str. 162-165) povećanu rizičnost pripisuju smanjenom interesu i naporima menadžera za nadgledanjem rizika portfelja (engl. *effort-aversion moral hazard* ili *dilution effect*). Pretpostavljajući da su menadžeri ujedno i dioničari banke (tzv. *ownership insiders*) kojima se zbog povećanja kapitalnih zahtjeva razvodnjava bogatstvo, zaključuje se da će oni biti manje motivirani za nadzor jer rezultate dijele s novim dioničarima. Ovim tumačenjem, problem na relaciji principal – agent dobiva novu dimenziju. Dodatno, Besanko i Kanatas (1996, str. 174-176) potvrđuju da je nakon prisilnih dokapitalizacija pad cijena bankovnih dionica utoliko veći, ukoliko je manji udio vlasništva menadžera u ukupnoj vlasničkoj strukturi banke. Pored slabijeg nadgledanja poslovnih rezultata, svoje razvodnjeno bogatstvo bankovni menadžeri mogu pokušati kompenzirati i troškovno – preferiranim ponašanjem, čime se smanjuje i ukupna efikasnost banke.

Afirmirajući dinamički pristup u analizi utjecaja adekvatnosti kapitala na bankovnu rizičnost, Blum (1999) se priklanja zaključcima o pozitivnoj vezi na relaciji kapital – rizik. Zbog ograničavajućeg učinka kapitalnih zahtjeva, dodatna jedinica kapitala, u budućoj perspektivi, dragocjenija je za banku. Ako je dokapitalizacija preskupa ili nije dostupna, jedini način da se u vremenskom pomaku kapital poveća jest da se poveća rizičnost bankovne aktive danas, a takvo ulaganje bude uspješno. Naime, restrikcija kapitala smanjuje očekivane profite banaka i one imaju manje za izgubiti u slučaju bankrota, zbog čega im povećanje rizičnosti nosi manje oportunitetne troškove (Blum, 1999, str. 756). Prema tome, „regulacija koja je imala za cilj učiniti bankarski sektor sigurnijim sutra, zapravo će učiniti poslovanje banaka rizičnijim danas“ (Blum, 1999, str. 765). Nastavno na prethodno, Hellmann *et al.* (2000, str. 155) ne osporavaju činjenicu da kapitalni zahtjevi mogu reducirati sklonost negativnoj selekciji (engl.

capital-at-risk effect) u jednom razdoblju (statički efekt), ali ističu da u dugom roku (dinamički efekt) može doći do erozije vrijednosti bankovne franšize (engl. *franchise-value effect*). Naime, u vremenskom pomaku, povratni efekt povećanog troška kapitala prepoznaje se u dodatnom smanjenju profitabilnosti pozajmljivanja, a time i daljnjih izgleda za razborite izbore plasmana, što ubrzano narušava vrijednost franšize banke te je u suprotnosti s funkcijom kapitala kao sredstvom umanjena negativne selekcije. Pored preuzimanja većih rizika u selekciji plasmana, Hellmann *et al.* (2000, str. 148) ističu i mogućnost prijevara te sukoba interesa prilikom odobravanja kredita poput kreditiranja bankovnih *insidera* (menadžera) i povezanih osoba, a sve s ciljem izvlačenja kapitala iz banaka nestabilnih izgleda za preživljavanje. Takvi potezi znani su i kao „kockanje za spas“ (engl. *gambling for resurrection*).

Polazeći od istraživanja Hellmann *et al.* (2000), koji (ne)uspjeh kapitalnih zahtjeva dovode u vezu s financijskom liberalizacijom te zaoštavanjem konkurencije u financijskom sektoru, Repullo (2004) ispituje efekte različitih regulatornih mjera na rizičnost aktiva banaka uzimajući u obzir stupanj konkurencije na tržištu depozita kao važnu odrednicu za ishod relacije kapital – rizik. Autor pretpostavlja da su depoziti osigurani, da deponenti snose trošak prilikom promjene banke, kao i da banke međusobno konkuriraju na tržištu depozita putem visine kamatnih stopa. Marža bankovnog posredništva upućuje na stupanj konkurencije na tržištu, pri čemu niske marže impliciraju visoku razinu konkurencije i obratno. Marža posredništva jednaka je pokazatelju troškova prijelaza deponenata u drugu banku u odnosu na broj banaka. U situaciji visokog stupnja konkurencije smanjena je vrijednost franšize banaka zbog čega u odsutnosti regulacije kapitala one ulažu isključivo u nerazborite aktive (engl. *gambling asset*). U slučaju visokih marži ili monopoliziranog tržišta i nepostojanja regulacije kapitala, banke će ulagati isključivo u razborite aktive (engl. *prudent asset*).

U modelu u kojem banke mogu ulagati isključivo u razborite aktive, vrijednost franšize banke (V_p) jednaka je $\frac{\mu}{\rho n^2}$, gdje je μ trošak odlaska deponenata iz banke, n broj banaka, a ρ trošak kapitala. Vrijednost franšize banke raste s troškovima odlaska deponenata i pada povećanjem broja banaka i rastom troška kapitala. Inače, izraz $\frac{\mu}{n}$ uzima se kao mjera tržišne snage banke. U modelu u kojem banke mogu ulagati isključivo u nerazborite aktive vrijednost franšize (V_G) je $\frac{(1-\pi)\mu}{(\rho+\pi)n^2}$, gdje je π vjerojatnost da ulaganja u nerazborite aktive ne uspiju i banka bude zatvorena. U tom slučaju, vrijednost franšize raste vjerojat-

nošću da ulaganje uspije ($1 - \pi$) i da je veći trošak odlaska deponenata te pada u slučaju da ulaganje ne uspije, trošak kapitala se poveća i broj banaka naraste. Prema tome, zaključuje se da regulacija kapitala smanjuje inicijativu za ulaganjima u rizične aktive (engl. *capital-at-risk effect*). Stabilizirajući utjecaj regulacije kapitala Repullo (2004) tumači smanjenjem kamatnih stopa na depozite (zbog troška regulacije kapitala) zbog čega se ne javlja efekt smanjenja franšizne vrijednosti banke. Ako se regulacija kapitala shvati u smislu kapitalnih zahtjeva, ulaganja u razborite aktive ne nose trošak u smislu bankovnog kapitala, što u konačnici destimulira ili penalizira nerazborite odluke. Repullo (2004, str. 169-170), stoga, predlaže veće minimalne kapitalne zahtjeve u okruženjima s mogućnostima za visokorizična ulaganja i visokim stupnjem konkurencije. Autor zaključuje da je regulacija kapitala putem kapitalnih zahtjeva opravdana i podjednako primjenjiva jer ne ovisi o stupnju tržišne snage banke.

Za razliku od svojih prethodnika, Calem i Rob (1999) ne daju jednoobrazan odgovor po pitanju utjecaja kapitalnih zahtjeva na rizičnost bankovnog poslovanja, već prvenstveno ističu važnost inicijalne razine kapitaliziranosti banke za strukturiranje portfelja. Dakle, prvi su sustavno objasnili da banke različite razine kapitaliziranosti mogu različito reagirati na kapitalne i druge regulatorne zahtjeve, dok je većina prethodnih istraživanja statički promatrala granične učinke povećanja kapitala na izbor portfelja reprezentativne banke. Dinamičkim pristupom Caleb i Rob (1999) potvrdili su da odnos između kapitala i preuzimanja rizika ima oblik „U“. To znači da su *ex ante* potkapitalizirane i visoko kapitalizirane banke sklone povećati rizičnost aktiva više od banaka umjerenih razina kapitaliziranosti. Odnosno, povećanjem kapitala od potkapitaliziranih banaka na dalje smanjuje se razina rizičnosti aktive i ponovno raste kod visoko ili prekapitaliziranih banaka. U slučaju potkapitaliziranih banaka inicijativa za pretjeranim ili maksimalno rizičnim – hazarderskim ponašanjem posljedica je iskorištavanja prisutnosti sustava osiguranja depozita, dok u slučaju prekapitaliziranih banaka dolazi od visoke profitabilnosti takvih investicija i male vjerojatnosti bankrota banaka koje ih poduzimaju. Naime, autori razlikuju klasični moralni hazard koji pripisuju nižim razinama kapitaliziranosti te inkrementalno povećanje rizičnosti koje se javlja na višim razinama kapitaliziranosti banaka, a koje nema za cilj prebacivanje neuspjeha ulaganja na sustav osiguranja depozita. Trošak ulaganja u rizičnu aktivu jest gubitak budućih zarada u slučaju insolventnosti, dok su korist prebacivanje duga na institucije osiguranja depozita i atraktivniji prinosi (Calem i Rob, 1999, str. 329-330). Naime, pretpostavljajući da se banke mogu dokapitalizirati isključivo zadržavanjem zarada, potkapitalizirane banke s tim ciljem povećavaju rizičnost, jer gubitak ili neuspjeh takvih

investicija u slučaju insolventnosti saldira sustav osiguranja depozita i tek manjim dijelom dioničari. Iz toga proizlazi da se moralni hazard može pripisati isključivo potkapitaliziranim bankama. Slabo kapitalizirane banke ne samo da ne smanjuju veličinu svoje aktive nego primjeri iz prakse potvrđuju da one mogu i dodatno rasti. Ipak, u modelu je veličina banke nepromjenjiva varijabla. S većom kapitaliziranosti banaka inicijativa za preuzimanjem pretjeranih rizika prvo opada i postaje umjerenija jer gubitke solventnih banaka snose sami dioničari. Kod visokih razina kapitaliziranosti zalihe kapitala dopuštaju bankama veće preuzimanje rizika jer je vjerojatnost da će postati insolventne mala. Posljednji zaključak vrijedi u slučaju regulacije kapitala jednostavnim pokazateljem financijske poluge, kao i u slučaju regulacije putem kapitalnih zahtjeva. Restriktivnija regulacija kapitala kod dobro kapitaliziranih banaka dovest će do povećanja rizičnosti njihova portfelja povećanjem kapitaliziranosti. Ako banke posjeduju zadovoljavajuću razinu kapitaliziranosti, za očekivati je da se dodatnim zahtjevima za povećanjem kapitala ne može značajnije smanjiti vjerojatnost njihove insolventnosti (Calem i Rob, 1999, str. 336). Općenito, banke neće smanjivati rizik portfelja kako bi se uskladile s regulacijom kapitala.

Izvođeci krivulju oblika „U“, Calem i Rob (1999) pomirili su suprotstavljene zaključke dotadašnjih istraživanja o odnosu kapitala i rizika banaka. U radu se, osim efekata regulacije kapitala, ispituje utjecaj uvođenja riziku banke počešenih premija osiguranja depozita na rizičnost portfelja. U modelu u kojem je kapital unaprijed zadan rezultati potvrđuju da potkapitalizirane banke koje su izložene plaćanju viših premija na osiguranje depozita nastoje povećati rizičnost aktiva, dok na dobro kapitalizirane banke varirajuće premije nemaju značajniji utjecaj. Plaćanje viših premija smanjuje očekivanu sadašnju vrijednost budućih profita banaka, što smanjuje oportunitetne troškove preuzimanja rizika (Calem i Rob, 1999, str. 334). Ako se dopusti mogućnost dokapitalizacije putem emisija novih dionica, potkapitalizirane banke, koje mogu eksterno prikupiti kapital, gube inicijativu za povećanjem rizičnosti portfelja. Konačno, tržišno discipliniranje od strane neosiguranih deponenata može se smatrati korisnim kod potkapitaliziranih banaka samo ako su oni sposobni *ex ante* uključiti rizičnost bankovnog portfelja u zahtijevanu premiju rizika. U suprotnom, *ex post* prepoznavanje rizičnosti (nakon erozije kapitala ili gubitaka) može samo dovesti do rizičnijeg ponašanja potkapitaliziranih banaka. Iz toga proizlazi da varirajuće premije osiguranja depozita nisu najsretnije rješenje za destimuliranje pretjerano rizičnog ponašanja banaka. S druge strane, dokazi ovih autora idu u prilog pozornijem nadziranju potkapitaliziranih banaka i zahtijevanju povećanja njihova kapitala.

Prema Milne i Whalley (2001), potencijalne regulatorne sankcije zbog nedovoljne kapitaliziranosti djeluju kao *ex ante* poticajni mehanizam na banke koje odlikuje dovoljna vrijednost franšize, tako da su one sklone održavati kapitaliziranosti iznad minimalno zahtijevane. Naime, vrijednost franšize u pozitivnoj je nelinearnoj vezi s održavanjem visine kapitaliziranosti iznad regulatornog minimuma. Na nižim razinama franšizne vrijednosti postoji inicijativa banaka da održavaju vrlo visoku kapitaliziranost, dok na visokim razinama franšizne vrijednosti kapitaliziranost opada. Prema tome, inicijativa za preuzimanjem rizika ovisit će o visini kapitala iznad regulatorno zahtijevanog, a ne o ukupnoj razini kapitaliziranosti. U kratkom roku, dok se banka ne dokapitalizira, može doći do privremene averzije prema riziku, tj. redukcije u pozajmljivanju, a samo kod insolventnih banaka do hazarderskog ponašanja. U dugom roku, povećanje regulatornog kapitala neće se odraziti na preuzimanje rizika. Ovim zaključcima Milne i Whalley (2001) postavljaju temelje novoj teoriji koja objašnjava utjecaj kapitalnih zahtjeva na ponašanje banaka pod pretpostavkom kapitala kao zaštite (engl. *capital buffer theory*) umjesto teorije moralnog hazarda koja je do tada dominirala. Putem teorije kapitala kao zaštite dugoročno promišljanje banaka, opreznost, franšizna vrijednost i inicijative koje uzrokuju određeno ponašanje banaka dobivaju primat pred objašnjenjima o bankama kao hazarderskim institucijama, kratkoročnih pogleda, koje isključivo održavaju minimalno zahtijevanu razinu kapitaliziranosti zbog čega kontinuirano moraju prilagođavati rizičnost aktive. Na tom idejnom tragu bio je i Marcus (1984). Moralni hazard tako je rezerviran samo za banke iznimno niske razine franšizne vrijednosti, tj. ugroženih budućih zarada ili potencijala za rast.

Kakav će biti utjecaj kapitaliziranosti na razinu rizičnosti bankovnog poslovanja prema Jeitschko i Jeung (2005), ovisi o tome koja interesno-utjecajna skupina dominira – osiguravatelji depozita, dioničari ili bankovni menadžeri. Statičkim pristupom došli su do sljedećih spoznaja:

- *Najpoželjnija rizičnost aktive s aspekta osiguravatelja depozita.* Povećanje kapitaliziranosti smanjuje vjerojatnost propasti banaka djelovanjem kapitala kao amortizera (engl. *buffer effect of capital*) zbog čega osiguravatelj depozita postaje popustljiviji u pogledu preuzimanja rizika banaka visokih kapitaliziranosti. Naime, osiguravatelj depozita ima za cilj minimizirati trošak propasti banaka za sustav osiguranja depozita. U radu se pretpostavlja da su svi depoziti u potpunosti osigurani te da je premija osiguranja depozita fiksirana.
- *Najpoželjnija rizičnost aktive s aspekta dioničara banaka.* Dioničari slabo kapitaliziranih banaka nastoje maksimizirati opcijsku vrijednost osigura-

nja depozita ulažući u rizičnije aktive od dioničara visoko kapitaliziranih banaka. Dioničari visoko kapitaliziranih banaka imaju mnogo više za izgubiti u slučaju bankrota banke zbog čega su skloniji manje rizičnom ponašanju. Naime, dioničar nastoji maksimizirati očekivanu vrijednost vlastitog kapitala koja se sastoji od sume: 1) razlike očekivanog prinosa od investicijskih projekata i plaćanja deponentima te 2) opcijske vrijednosti osiguranja depozita (Jeitschko i Jeung, 2005, str. 768). „Analiza sugerira da regulacija kapitala može služiti kao instrument usklađivanja preferencija za rizikom dioničara s onima osiguravatelja depozita“ (Jeitschko i Jeung, 2005, str. 769). Nekonzistentnost ovih rezultata s dijelom teorijskih radova Jeitschko i Jeung (2005, str. 769-770) argumentiraju činjenicom da prethodni radovi zanemaruju slučaj linearnog odnosa rizika i prinosa, kao i činjenicu da interesi dioničara i menadžera mogu biti suprotstavljeni. Autori zapažaju da su se dotadašnje analize (izuzev, primjerice, Besanko i Kanatas, 1996) redovito fokusirale na agencijski problem između dioničara i vjerovnika (u krajnjem slučaju, sustava osiguranja depozita) i uglavnom zanemarile agencijski problem između dioničara i njihovih agenata.

- *Najpoželjnija rizičnost aktive s aspekta menadžera banaka.* Povećanjem kapitaliziranosti banke može se očekivati da će menadžeri težiti rizičnijim ulaganjima ako se time može povećati njihova privatna korist. Inicijativa za manje rizičnim ulaganjima menadžera u odnosu na dioničare dolazi od uske povezanosti menadžerskih naknada i nagrada s ukupnim rizikom banke te njezinim financijskim performansama. Za razliku od menadžera, dioničari mogu nastojati diversificirati rizik. S druge strane, rizičniji obrazac ponašanja menadžera također može imati uporište u kompenzacijskom menadžmentu banke koji naročito podržava pretjerani rast njezine aktive. U svakom slučaju, menadžeri nastoje maksimizirati očekivanu vrijednost svojih privatnih koristi koje se u modelu izjednačavaju s umnoškom privatnih koristi i vjerojatnosti solventnosti banke (Jeitschko i Jeung, 2005, str. 770).

Iz navedenog proizlazi da interesi dioničara moraju dominirati u odnosu na ostale interesne skupine kako bi viša razina kapitaliziranosti dovela do smanjenja rizičnih aktivnosti banaka. Ako dominiraju interesi menadžera, za očekivati je porast rizičnosti s višom razinom kapitaliziranosti. Interesi dioničara trebali bi biti zastupljeniji kod banaka čijim se dionicama ne trguje na organiziranim tržištima kapitala, dok bi interesi menadžera mogli dominirati kod kotirajućih banaka.

Zaključci predočenih istraživanja mogu se klasificirati u sljedeće skupine: 1) povećanje kapitala povećava sklonost riziku, tj. moralni hazard (engl. *expected income effect*) (Koehn i Santomero, 1980; Kim i Santomero, 1988; Gennotte i Pyle, 1991; Rochet, 1992; Besanko i Kanatas, 1996; Blum, 1999; Hellmann *et al.*, 2000), 2) povećanje kapitala reducira inicijativu za preuzimanje većih rizika (engl. *capital-at-risk effect*) (Furlong i Keeley, 1987, 1989; Keeley i Furlong, 1990; Repullo, 2004) i 3) ne postoji jednoznačan odgovor, odnosno isti ovisi o inicijalnoj razini kapitaliziranosti te drugim faktorima iz internog i eksternog okruženja banke (Calem i Rob, 1999; Milne i Whalley, 2001; Jeitschko i Jeung, 2005).

Ovim pregledom literature nisu obuhvaćeni mnogi radovi o međuovisnosti kapitaliziranosti i rizičnosti bankovnog poslovanja, ali je zasigurno dan uvid u relevantne teorijske iskorake u analizi promatranog fenomena. Naknadni radovi nastavili su problematizirati odnos kapitala i rizika, ali uglavnom preispitujući opravdanost kapitalnih zahtjeva koji su osjetljivi na rizik, s obzirom na to da rizičnost bankovne aktive često ne može biti dovoljno precizno izmjerena. Tako, Ahnert *et al.* (2021) zaključuju da, u slučaju nedovoljno precizne procjene rizika, regulatori trebaju biti skloniji kapitalnim zahtjevima koji nisu podešeni riziku, dok porastom točnosti procjena i eliminiranjem izrazito rizičnih projekata kapitalni zahtjevi trebaju biti postavljeni na nižim razinama rizične osjetljivosti. Na sličan način Agénor i Pereira da Silva (2021) ističu da je zahtijevani regulatorni kapital potencijalno previsoko postavljen te da treba biti promatran u kontekstu drugih regulatornih i supervizorskih instrumenata da se stabilnost financijskog tržišta ne bi postizala na uštrb smanjenog financijskog posredništva banaka. Stoga, Mérő (2021) predlaže kompromis u vidu kombiniranog pristupa regulaciji bankovnog kapitala umjesto podržavanja isključivih prijedloga koji idu u smjeru kapitalnih zahtjeva koji nisu podešeni riziku ili kapitalnih zahtjeva koji su isključivo rizično osjetljivi. U nastavku rada naglasak je na rezultatima empirijskih istraživanja.

3. EMPIRIJSKI DOKAZI O (SU)ODNOSU KAPITALA I RIZIKA BANAKA

Empirijska istraživanja o uzajamnoj određenosti promjena u kapitalu i riziku banaka obično slijede metodološki obrazac Shrieves i Dahl (1992), koji su među prvima sustavno empirijski ispitali determinante promjena u kapitaliziranosti i rizičnosti banaka.

Prema Shrieves i Dahl (1992), promjene u kapitaliziranosti ($\Delta CAP_{j,t}$) i promjene u rizičnosti ($\Delta RISK_{j,t}$) banke određene su endogenim, kontrolabilnim ili diskrecijskim prilagodbama ($\Delta CAP_{j,t}^M$, $\Delta RISK_{j,t}^M$) i egzogenim čimbenicima ($\tilde{E}_{j,t}$, $\tilde{U}_{j,t}$) tako da je:

$$\Delta CAP_{j,t} = \Delta CAP_{j,t}^M + \tilde{E}_{j,t} \quad (1)$$

$$\Delta RISK_{j,t} = \Delta RISK_{j,t}^M + \tilde{U}_{j,t} \quad (2)$$

Diskrecijske promjene u kapitalu ($\Delta CAP_{j,t}^M$) i riziku ($\Delta RISK_{j,t}^M$) određene su razlikom između ciljanih razina kapitala i rizika ($CAP_{j,t}^*$, $RISK_{j,t}^*$) te razina kapitala ($CAP_{j,t-1}$) i rizika ($RISK_{j,t-1}$) u prethodnom razdoblju:

$$\Delta CAP_{j,t}^M = \alpha(CAP_{j,t}^* - CAP_{j,t-1}) \quad (3)$$

$$\Delta RISK_{j,t}^M = \beta(RISK_{j,t}^* - RISK_{j,t-1}) \quad (4)$$

Prema tome je:

$$\Delta CAP_{j,t} = \alpha(CAP_{j,t}^* - CAP_{j,t-1}) + \tilde{E}_{j,t} \quad (5)$$

$$\Delta RISK_{j,t} = \beta(RISK_{j,t}^* - RISK_{j,t-1}) + \tilde{U}_{j,t} \quad (6)$$

gdje su α i β brzina prilagodbe kapitala i rizika, respektivno.

Ovom formulacijom uvažava se činjenica da banke mogu imati odstupanja od ciljanih razina kapitala i rizika, tj. da se ne mogu uvijek *ad hoc* potpuno prilagoditi njihovim željenim razinama. Ciljane razine kapitala i rizika nisu jednoznačno određene i ovise o specifičnostima banaka pa se u istraživanjima aproksimiraju nizom banko-specifičnih varijabli. Egzogene promjene kapitala mogu proizići iz regulatornih pritisaka za povećanjem kapitaliziranosti ili neočekivanih promjena u veličini zarada uzrokovanih oscilacijama operativne dobiti ili vrijednosti kredita, što utječe na volumen rezervacija, dok egzogene promjene rizika uključuju slučajne gospodarske šokove, poput promjena u potražnji za kreditima ili vrijednosti kolaterala (Shrieves i Dahl, 1992, str. 446-447). Shrieves i Dahl (1992) pozitivnu korelaciju između rizika i kapitala tumače kao rezultat regulatornih troškova, nenamjeranih učinaka minimalnih kapitalnih zahtjeva, izbjegavanja troškova bankrota ili averzije menadžera prema riziku, dok negativna korelacija može biti posljedica pogrešno postavljenih premija u sustavu osiguranja depozita.

S uporištem u metodološkom obrascu Shrieves i Dahl (1992), većina prijašnjih empirijskih istraživanja istovremeno je ispitala efekte kapitala na rizik i rizika na kapital, dok su se naknadna istraživanja uglavnom usredotočila na poslje-

dice kapitalnih zahtjeva na rizičnost banke. Naime, većina autora potvrdila je da povećanje rizika vodi ka povećanju kapitaliziranosti (npr. Shrieves i Dahl, 1992; Rime, 2001; Cannata i Quagliariello, 2006; Stolz, 2007; Matejašák *et al.*, 2009; Jokipii i Milne, 2011) te da je lakše, brže i troškovno učinkovitije mijenjati razinu kapitala nego razinu rizika (Rime, 2001; Cannata i Quagliariello, 2006; Stolz, 2007). Stoga su se naknadni radovi opravdano usmjerili na utjecaj kapitalnih zahtjeva na rizik banke, pri čemu se od promatranja ukupne bankovne kapitaliziranosti, preko viška kapitala iznad regulatorno zahtijevanog, došlo do analiziranja utjecaja strukture regulatornog kapitala na rizik aktive (najčešće mjeren rizikom ponderiranom aktivom u odnosu na ukupnu aktivu te neprihodonosnim kreditima u odnosu na ukupne kredite) i/ili ukupan rizik banke. Model simultanih jednadžbi i dinamički panel modeli najzastupljeniji su načini obrade podataka. Metodološka obilježja i zaključci, po mišljenju autorice, najrelevantnijih empirijskih istraživanja, predloženi su u Tablici 1. Apstrahirajući ih, zaključuje se sljedeće:

- Kapitalni zahtjevi mogu dovesti i do smanjenja i do povećanja rizičnosti aktiva, ali ako banke drže više kapitala od regulatorno zahtijevanog minimuma, dodatno preuzimanje rizika u aktivu ne mora predstavljati hazardsko ponašanje, već može biti dokaz teorije kapitala kao zaštite.
- Pored visine kapitaliziranosti, podjednako je važna struktura regulatorne kapitaliziranosti jer banke s više subordiniranog duga imaju rizičnije ponašanje.
- Kritike na račun kapitalnih zahtjeva, u smislu izazivanja rizičnijeg ili hazardskog ponašanja banaka, tijekom vremena slabe.

Tablica 1. Pregled metodoloških obilježja i zaključaka izabranih empirijskih istraživanja

Autori	Podaci / Obilježja uzorka	Zaključci
Shrieves i Dahl (1992)	SAD; 1983. – 1987. 1.800 komercijalnih banaka u sustavu osiguranja depozita s aktivom većom od 100 milijuna USD	Promjene u razini rizika i kapitala uzajamno su pozitivno određene. Promjene kapitaliziranosti pozitivno utječu na promjene u rizičnosti banke (mjereno rizikom ponderiranom aktivom). Povećanje rizičnosti banaka prati povećanje kapitaliziranosti kod banaka visoke i slabije kapitaliziranosti. Potkapitalizirane banke prilagođavaju se regulatornim pritiscima smanjenjem rizičnosti i povećanjem kapitaliziranosti.

Autori	Podaci / Obilježja uzorka	Zaključci
Haubrich i Wachtel (1993)	SAD; 1988. – 1992. 12.187 komercijalnih banaka	Usklađivanje s kapitalnim zahtjevima banaka povezano je s izmjenom strukture aktive u smjeru rasta udjela državnih obveznica i trezorskih zapisa ministarstva financija u portfelju na uštrb plasmana za nekretnine i kredite poduzećima, osobito kod slabije kapitaliziranih banaka.
Jacques i Nigro (1997)	SAD; 1990. – 1991. 2.570 komercijalnih banaka u sustavu osiguranja depozita s aktivom većom od 100 milijuna USD	Kapitalni zahtjevi doveli su do povećanja kapitaliziranosti i smanjenja rizičnosti portfelja komercijalnih banaka, pri čemu su izraženiji efekti kod banaka koje nisu bile pod regulatornim pritiskom.
Ediz <i>et al.</i> (1998)	Ujedinjeno Kraljevstvo; 1989. – 1995. 94 banke	Banke se prilagođavaju kapitalnim zahtjevima povećanjem osnovnog kapitala (Tier 1), dok je izmjena rizičnosti portfelja beznačajna.
Calem i Rob (1999)	SAD; 1984. – 1993. komercijalne banke s aktivom većom od 300 milijuna USD i najmanje 6 % kapitala u odnosu na aktivu (minimalna regulatorna kapitaliziranost)	Potkapitalizirane i prekapitalizirane banke sklone su rizičnijem ponašanju, odnosno postoji oblik „U“ odnosa između kapitala i rizika. Regulacija kapitala opravdana je kod potkapitaliziranih banaka. Općenito vrijedi da je regulacija kapitala poboljšala kapitaliziranost banaka.
Hovakimian i Kane (2000)	SAD; 1985. – 1994. 123 banke koje kotiraju na burzama NYSE, AMEX i Nasdaq	Slabije kapitalizirane banke imaju veće inicijative za rizičnim ponašanjem. Isto tako, banke koje povećaju rizičnost aktiva u budućnosti više se oslanjaju na financiranje depozitima u odnosu na neosigurani dug. Učinkovitost regulatornih pritisaka opada porastom veličine banke pa su velike banke i banke srednje veličine sklone podizanju rizičnosti poslovanja više i od malih banaka kod kojih dominiraju osigurani depoziti. Zaključno, banke koje imaju više depozita u odnosu na ostali dug imaju veće koristi od podizanja rizičnog profila. Motivi za rizično ponašanje najveći su kod banaka s problemima u poslovanju. Izmjene u premijama za osiguranje depozita nisu eliminirale inicijativu za rizičnijim ponašanjem, već su zbog povećavanja regulatornog troška dovele do podizanja rizičnog profila kod inače konzervativnih banaka. Prema tome, regulacija kapitala nije spriječila pojavu povećanja rizičnosti aktiva na uštrb sigurnosne mreže.

Autori	Podaci / Obilježja uzorka	Zaključci
Beatty i Gron (2001)	SAD; 1986. – 1995. 438 kotirajućih bankovnih holding-društava	Empirijski rezultati ne potvrđuju da su slabije kapitalizirane banke agresivnije u preuzimanju rizika. Općenito je dokazana komplementarnost kapitala i rizika, odnosno da povećanje kapitala prati povećanje rizika i obratno. Značajnije razlike u bankovnom ponašanju nisu uočene u razdoblju prije i nakon uvođenja kapitalnih zahtjeva.
Rime (2001)	Švicarska; 1989. – 1995. 154 banke u domaćem vlasništvu	Postoji pozitivna veza između promjene rizika i promjene kapitala u odnosu na aktivu. Regulatorni pritisci utječu na povećanje kapitala banaka, ali nemaju utjecaj na promjene u razini rizika.
Bichsel i Blum (2004)	Švicarska; 1990. – 2002. 19 kotirajućih banaka	Povećanje u kapitaliziranosti banaka od 1 % dovodi do povećanja rizičnosti aktive za 1,2 %.
Godlewski (2005)	30 razvijajućih zemalja iz područja Latinske Amerike (42 % uzorka), istočne Azije i Pacifika (< 25 % uzorka), južne Azije (17,5 % uzorka), istočne Europe i srednje Azije (15 % uzorka); 1996. – 2001. 2.779 banaka	Kada je razina adekvatnosti kapitala banke niska, banke nastoje smanjiti rizičnost, dok bolje kapitalizirane banke dodatno povećavaju kapitaliziranost. Regulacija kapitala u razvijajućim zemljama ne doprinosi u potpunosti postavljenim ciljevima, a njezina uspješnost determinirana je ostalim regulatornim te institucionalnim, zakonodavnim i varijablama okruženja.
Cannata i Quagliariello (2006)	Italija; 1994. – 2003. preko 500 banaka	Kapital i rizik uzajamno se određuju. Slabije kapitalizirane banke brže se prilagođavaju regulatornim pritiscima povećanjem kapitala, a sporije smanjenjem rizika.
Jeitschko i Jeung (2007)	Koreja; 2002. – 2004. 114 uzajamnih štednih banaka i 14 komercijalnih banaka	Slabije kapitalizirane štedne banke u pozitivnoj su vezi s rizikom, a potkapitalizirane komercijalne banke u negativnoj su vezi s rizikom. Bolje kapitalizirane štedne banke smanjuju rizičnost, a bolje kapitalizirane komercijalne banke povećavaju rizičnost. Regulatori značajnije utječu na štedne banke u odnosu na potkapitalizirane komercijalne banke. Također, postoje razlike u odnosu kapitala i rizika u ovisnosti o dominaciji različitih inicijativa interesnih skupina. Interesi menadžera dominiraju kod dobro kapitaliziranih banaka čijim se dionicama javno trguje i manifestiraju se u povećanju rizika. Interesi dioničara dominiraju kod dobro kapitaliziranih štednih banaka tako da umanjuju rizik.

Autori	Podaci / Obilježja uzorka	Zaključci
Stolz (2007)	Njemačka; 1993. – 2004. 570 štednih banaka	Višak kapitaliziranosti banaka u odnosu na regulatorno zahtijevanu razinu utječu na brzinu prilagodbe kapitala i rizika te koordinaciju promjena u riziku i promjena u kapitalu. Banke koje su po kapitaliziranosti bliže regulatornom minimumu brže se prilagođavaju od banaka suprotnih karakteristika smanjujući rizik i povećavajući kapital. Banke čija je kapitaliziranost udaljenija od regulatornog minimuma povećavaju rizik kada se poveća kapital, ali ne i obratno. Općenito, banke brže prilagođavaju kapital u odnosu na prilagodbu rizičnog profila.
Van Roy (2008)	6 država G-10 (Kanada, Francuska, Italija, Japan, Ujedinjeno Kraljevstvo, SAD); 1988. – 1995. 576 komercijalnih banaka s aktivom većom od 100 milijuna USD, uz isključenje bankovnih holding-društava (čak – 459 banaka iz uzorka je iz SAD-a)	Kapitalni zahtjevi imaju ograničene učinke na povećanje kapitala i smanjenje kreditnog rizika izvan SAD-a. U SAD-u je zabilježeno komplementarno djelovanje regulatornih i tržišnih pritisaka.
Matejašák <i>et al.</i> (2009)	SAD i EU-15; 2000. – 2005. 1.263 banke (580 banaka iz zemalja EU-15 i 683 banke iz SAD-a)	Kapitalni zahtjevi ostvaruju svoju funkciju u smislu povećanja kapitala i redukcije rizika.
Mammel i Raupach (2010)	Njemačka; 1998. – 2006. 81 velika banka	Velike njemačke banke prilagođavaju se kapitalnim zahtjevima najčešće na strani aktive (putem portfelja vrijednosnih papira za trgovanje) te, stoga, drže nisku razinu viška kapitala iznad regulatorno zahtijevanog.
Jokipii i Milne (2011)	SAD; 1986. – 2008. komercijalne banke i kotirajuća bankovna holding-društva	Dobro kapitalizirane banke sklone su dodatnom preuzimanju rizika.
Saadaoui (2011)	130 banaka iz 10 razvijenih zemalja članica Bazelskog odbora i 307 banaka iz 29 razvijajućih zemalja); 1995. – 2005. 437 komercijalnih banaka s aktivom većom od 100 milijuna USD	Postoje značajne razlike u rezultatima za razvijene i razvijajuće zemlje, pri čemu je ponašanje banaka u razvijenim zemljama više u skladu s regulatornim očekivanjima. U razvijajućim zemljama regulatorni pritisci slabo djeluju na povećanje kapitaliziranosti te uzrokuju povećanje rizika kod potkapitaliziranih banaka.

Autori	Podaci / Obilježja uzorka	Zaključci
Camara <i>et al.</i> (2013)	17 europskih zemalja; 1992. – 2006. do 1.451 komercijalna, štedna, uzajamna banka i kooperativa (od čega 677 iz Italije i 226 iz Francuske)	Struktura regulatornog kapitala važna je za preuzimanje rizika. Banke s više subordiniranog duga u kapitalnim zahtjevima sklonije su dodatnom preuzimanju rizika.
Guidara <i>et al.</i> (2013)	Kanada; 1982. – 2010. 6 najvećih banaka	Nije dokazan utjecaj viška kapitala iznad regulatorno zahtijevanog na rizik. Dobra kapitaliziranost banaka vjerojatno je uzrokovana tržišnim discipliniranjem.
Duran i Lozano-Vivas (2014)	SAD; 1998. – 2011. 34.482 opažanja (46 % banaka povećalo je rizike)	Držanje regulatornog kapitala značajno iznad minimalno zahtijevanog smanjuje preuzimanje rizika.
Ghosh (2014)	Zemlje GCC-a (engl. <i>Gulf Cooperation Council</i>); 1996. – 2011. oko 100 komercijalnih i islamskih banaka	Banke ne povećavaju rizik nakon povećanja kapitaliziranosti, ali povećavaju kapital nakon povećanja rizika. Islamske banke sklonije su povećavati kapitaliziranost u odnosu na konvencionalne banke.
Šútorová i Teplý (2014)	Zemlje EU-27; 2006. – 2011. 594 banke	Banke ne povećavaju kreditni rizik nakon povećanja kapitaliziranosti. Upravo suprotno, kapitaliziranost vodi smanjenju rizika i profitabilnosti banaka.
Leung <i>et al.</i> (2015)	SAD; 2006. – 2011. 227 kotirajućih bankovnih holding-društava s aktivom većom od 500 milijuna USD	Banke s većim viškom osnovnog kapitala (Tier 1) iznad regulatorno zahtijevanog manje su rizične (aproximirano ukupnim i pojedinačnim, tj. dekomponiranim rizicima).
Bitar <i>et al.</i> (2016)	17 zemalja MENA-e; 1999. – 2013. 168 banaka	Za smanjenje rizika banaka i bolje upravljanje rizicima važna je razvijenost institucionalnog okruženja te veći udio osnovnog kapitala u regulatornom kapitalu.
Cappelletti <i>et al.</i> (2019)	Eurozona; 2014. – 2017. 110 drugih sistemski važnih bankarskih institucija	Višak kapitala iznad regulatorno zahtijevanog smanjuje preuzimanje rizika kod drugih sistemski važnih banaka.
Jiang <i>et al.</i> (2020)	Kina; 2004. – 2017. 135 banaka	Postoji oblik „U“ odnosa između viška kapitala iznad regulatorno zahtijevanog i rizika.
Li (2021)	118 zemalja; 2001. – 2016. preko 7.600 banaka	Banke s većim pokazateljem osnovnog kapitala averzne su prema riziku, dok su one s više subordiniranog duga u strukturi kapitalnih zahtjeva sklonije preuzimanju rizika. U prisutnosti veće konkurencije i globalne financijske krize ovi zaključci još su uvjerljiviji.

Izvor: izrada autorice temeljena na analizi popisane literature

U konačnici, empirijski dokazi za države jugoistočne Europe prilično su rijetki. Primjerice, za banke jugoistočne Europe u razdoblju od 2000. do 2010. godine Kundid Novokmet (2021) potvrdila je da, ako imaju višak kapitala iznad regulatorno zahtijevanog, povećavaju rizičnost aktive, ali smanjuju cjelokupni rizik poslovanja mjeren indeksom rizika. No, dodatan oprez potreban je kod velikih banaka i banaka koje drže svoju regulatornu kapitaliziranost na minimumu jer su sklone uvećanom preuzimanju rizika. Sve navedeno potvrđuje važnost daljnjeg praćenja ovog regulatornog koncepta, uvažavajući njegove periodičke izmjene, ali i raspoloživost novih metodoloških alata te dostupnost preciznijih podataka.

4. ZAKLJUČAK

Usklađivanje s kapitalnim režimom desetljećima je kontroverzno pitanje bankarske teorije i prakse. Iako se očekivalo da će implementacija regulacije banaka putem kapitalnih zahtjeva prevenirati nastanak bankarskih kriza, u najboljem slučaju ona doprinosi smanjenju vjerojatnosti krize i javnih troškova zbog njezine pojave, prebacujući značajniji dio odgovornosti na dioničare banaka. Međutim, od uvođenja kapitalnih zahtjeva taj učinak je često problematiziran s obzirom na to da za svoje dodatne uloge dioničari mogu tražiti i veći prinos, koji se može ostvariti samo značajnijim preuzimanjem rizika. Prvotno se takvo ponašanje tretiralo kao kontraučinkovito, a objedinjeno je u teoriji moralnog hazarda. Ipak, kako je vrijeme pokazalo da banke uglavnom održavaju regulatorni kapital iznad minimalno zahtijevanog kako bi bez straha od regulatorne intervencije mogle primjereno rasti i funkcionirati, razvila su se i alternativna tumačenja poput teorije kapitala kao zaštite prema kojoj banke uistinu povećanjem kapitaliziranosti preuzimaju i dodatne rizike u aktivni, što se ne može okarakterizirati kao hazardersko, već racionalno ili oportuno ponašanje. Naime, pri istraživanju odnosa bankovnog kapitala i rizika nužno je uzeti u obzir inicijalnu razinu kapitaliziranosti ili višak kapitaliziranosti iznad regulatorno zahtijevane razine te veličinu ili sistemski značaj banke. Tako se povećano preuzimanje rizika minimalno kapitaliziranih, a sistemski važnih banaka može okarakterizirati kao nerazborito ponašanje, a mjera kapitalnih zahtjeva neučinkovita. Kod dobro kapitaliziranih banaka nepreuzimanje dodatnih rizika u poslovanju značilo bi da takve banke nisu dovoljno funkcionalne ili da su pretjerano oprezne. U svakom slučaju, neupotrebljavanje regulatornog kapitala za rast i preuzimanje rizika predstavlja njegovu suboptimalnu upotrebu. Tome

u prilog idu i empirijski dokazi o efektima kapitalnih zahtjeva na bankovne rizike, koji, iako od početaka imaju neujednačene rezultate, ipak u posljednje vrijeme potvrđuju smislenost promatranog regulatornog režima, naročito kada se regulatorna kapitaliziranost i njezina struktura dovode u vezu s ukupnim rizicima banke, a ne samo rizičnošću aktive. Naredna istraživanja trebala bi ponuditi odgovore potrebne za daljnje kalibriranje kapitalnih zahtjeva i ići u smjeru dekompozicije ukupnih bankovnih rizika na uobičajene vrste. Također je neophodno kritički razmotriti ideju „zelenih“ kapitalnih zahtjeva te napraviti simulacije vezane uz posljedice uvažavanja rizika okoliša u izračun regulatornog kapitala, kao i obratno, utvrditi otpornost kapitalnih pozicija na fizičke i tranzitorne rizike.

REFERENCE

1. Ahnert, T., Chapman, J. i Wilkins, C. (2021) Should Bank Capital Regulation Be Risk Sensitive?, *Journal of Financial Intermediation*, Vol. 46, April, 100870.
2. Agénor, P. – R. i Pereira da Silva, L. A. (2021) Capital Requirements, Risk-Taking and Welfare in a Growing Economy, *Journal of Regulatory Economics*, Vol. 60, str. 167-192.
3. Beatty, A. L. i Gron, A. (2001) Capital, Portfolio, and Growth: Bank Behavior Under Risk-Based Capital Guidelines, *Journal of Financial Services Research*, Vol. 20, No. 1, str. 5-31.
4. Besanko, D. i Kanatas, G. (1996) The Regulation of Bank Capital: Do Capital Standards Promote Bank Safety?, *Journal of Financial Intermediation*, Vol. 5, No. 2, str. 160-183.
5. Bichsel, R. i Blum, J. (2004) The Relationship between Risk and Capital in Swiss Commercial Banks: A Panel Study, *Applied Financial Economics*, Vol. 14, No. 8, str. 591-597.
6. Bitar, M., Saad, W. i Benlemlih, M. (2016) Bank Risk and Performance in the MENA Region: The Importance of Capital Requirements, *Economic Systems*, Vol. 40, No. 3, str. 398-421.
7. Blum, J. (1999) Do Capital Adequacy Requirements Reduce Risks in Banking?, *Journal of Banking and Finance*, Vol. 23, No. 5, str. 755-771.
8. Calem, P. i Rob, R. (1999) The Impact of Capital-Based Regulation on Bank Risk-Taking, *Journal of Financial Intermediation*, Vol. 8, No. 4, str. 317-352.
9. Camara, B., Lepetit, L. i Tarazi, A. (2013) Ex Ante Capital Position, Changes in the Different Components of Regulatory Capital and Bank Risk, *Applied Economics*, Vol. 45, No. 34, str. 4831-4856.
10. Cannata, F. i Quagliariello, M. (2006) Capital and Risk in Italian Banks: A Simultaneous Equation Approach, *Journal of Banking Regulation*, Vol. 7, No. 3-4, str. 283-297.
11. Cappelletti, G., Ponte Marques, A., Varraso, P., Budrys, Ž. i Peeters, J. (2019). Impact of Higher Capital Buffers on Banks' Lending and Risk-Taking: Evidence from the Euro Area Experiments, *European Central Bank, Working Paper Series*, No. 2292, June.

12. Duran, M. A. i Lozano-Vivas, A. (2014) Risk Shifting in the US Banking System: An Empirical Analysis, *Journal of Financial Stability*, Vol. 13, August, str. 64-74.
13. Ediz, T., Michael, I. i Perraudin, W. (1998) The Impact of Capital Requirements on U.K. Bank Behaviour, Federal Reserve Bank of New York, *Economic Policy Review*, Vol. 4, No. 3, str. 15-22.
14. Furlong, F. T. i Keeley, M. C. (1987) Bank Capital Regulation and Asset Risk, Federal Reserve Bank of San Francisco, *Economic Review*, No. 2, str. 20-40.
15. Furlong, F. T. i Keeley, M. C. (1989) Capital Regulation and Bank Risk-Taking: A Note, *Journal of Banking and Finance*, Vol. 13, No. 6, str. 883-891.
16. Gennotte, G. i Pyle, D. (1991) Capital Controls and Bank Risk, *Journal of Banking and Finance*, Vol. 15, No. 4-5, str. 805-824.
17. Ghosh, S. (2014) Risk, Capital and Financial Crisis: Evidence for GCC Banks, *Borsa Istanbul Review*, Vol. 14, No. 3, str. 145-157.
18. Godlewski, C. J. (2005) Bank Capital and Credit Risk Taking in Emerging Market Economies, *Journal of Banking Regulation*, Vol. 6, No. 2, str. 128-145.
19. Guidara, A., Lai, V. S., Soumaré, I. i Tchana, F. T. (2013) Banks' Capital Buffer, Risk and Performance in the Canadian Banking System: Impact of Business Cycles and Regulatory Changes, *Journal of Banking and Finance*, Vol. 37, No. 9, str. 3373-3387.
20. Haubrich, J. G. i Wachtel, P. (1993) Capital Requirements and Shifts in Commercial Bank Portfolios, Federal Reserve Bank of Cleveland, *Economic Review*, Vol. 29, No. 3, str. 2-15.
21. Hellmann, T. F., Murdock, K. C. i Stiglitz, J. E. (2000) Liberalization, Moral Hazard in Banking, and Prudential Regulation: Are Capital Requirements Enough?, *The American Economic Review*, Vol. 90, No. 1, str. 147-165.
22. Hovakimian, A. i Kane, E. J. (2000) Effectiveness of Capital Regulation at U.S. Commercial Banks, 1985-1994, *The Journal of Finance*, Vol. 55, No. 1, str. 451-468.
23. Jacques, K. i Nigro, P. (1997) Risk-Based Capital, Portfolio Risk, and Bank Capital: A Simultaneous Equations Approach, *Journal of Economics and Business*, Vol. 49, No. 6, str. 533-547.
24. Jeitschko, T. D. i Jeung, S. D. (2005) Incentives for Risk-Taking in Banking – A Unified Approach, *Journal of Banking and Finance*, Vol. 29, No. 3, str. 759-777.
25. Jeitschko, T. D. i Jeung, S. D. (2007) Do Well-Capitalized Banks Take More Risk? Evidence from the Korean Banking System, *Journal of Banking Regulation*, Vol. 8, No. 4, str. 291-315.
26. Jiang, H., Zhang, J. i Sun, C. (2020) How Does Capital Buffer Affect Bank Risk-Taking? New Evidence from China Using Quantile Regression, *China Economic Review*, Vol. 60, April, 101300.
27. Jokipii, T. i Milne, A. (2011) Bank Capital Buffer and Risk Adjustment Decisions, *Journal of Financial Stability*, Vol. 7, No. 3, str. 165-178.
28. Keeley, M. C. i Furlong, F. T. (1990) A Reexamination of Mean-Variance Analysis of Bank Capital Regulation, *Journal of Banking and Finance*, Vol. 14, No.1, str. 69-84.

29. Kim, D. i Santomero, A. M. (1988) Risk in Banking and Capital Regulation, *The Journal of Finance*, Vol. 43, No. 5, str. 1219-1233.
30. Koehn, M. i Santomero, A. M. (1980) Regulation of Bank Capital and Portfolio Risk, *The Journal of Finance*, Vol. 35, No. 5, str. 1235-1244.
31. Kupid, A. (2013) *Primjerenost kapitalnih zahtjeva za stabilnost bankarskog sektora*. Doktorska disertacija. Ekonomski fakultet Sveučilišta u Splitu: Split.
32. Kupid, A. (2014) Uzroci trajne neučinkovitosti bankovne regulacije, poglavlje u knjizi *Financije nakon krize: forenzika, etika i održivost* (ur. Ćurak, M., Kupid, A. i Visković, J.), Split: Sveučilište u Splitu, Ekonomski fakultet, str. 1-23.
33. Kupid Novokmet, A. (2015) Kontroverze regulacije banaka kroz kapitalne zahtjeve, *Ekonomski pregled*, Vol. 66, No. 2, str. 156-176.
34. Kupid Novokmet, A. (2021) Do Capital Buffers Add to Bank Risk-Taking in South-Eastern Europe? A Look at the Pre-Basel III Period, poglavlje u knjizi *The Changing Financial Landscape: Financial Performance Analysis of Real and Banking Sectors in Europe* (ur. Karanović, G., Polychronidou, P. i Karasavoglou, A.), Cham: Springer, str. 141-169.
35. Lastra, R. M. (2004) Risk-Based Capital Requirements and Their Impact upon the Banking Industry: Basel II and CAD III, *Journal of Financial Regulation and Compliance*, Vol. 12, No. 3, str. 225-239.
36. Leung, W. S., Taylor, N. i Evans, K. P. (2015) The Determinants of Bank Risks: Evidence from the Recent Financial Crisis, *Journal of International Financial Markets, Institutions and Money*, Vol. 34, January, str. 277-293.
37. Li, S. (2021) Quality of Bank Capital, Competition, and Risk-Taking: Some International Evidence, *Emerging Markets Finance and Trade*, Vol. 57, No. 12, str. 3455-3488.
38. Marcus, A. J. (1984) Deregulation and Bank Financial Policy, *Journal of Banking and Finance*, Vol. 8, No. 4, str. 557-565.
39. Matejašák, M., Teplý, P. i Černohorský, J. (2009) The Impact of Regulation of Banks in the US and the EU-15 Countries, *E+M Ekonomie a Management*, Vol. 12, No. 3, str. 58-68.
40. Memmel, C. i Raupach, P. (2010) How Do Banks Adjust their Capital Ratios?, *Journal of Financial Intermediation*, Vol. 19, No. 4, str. 509-528.
41. Mörö, K. (2021) The Ascent and Descent of Banks' Risk-Based Capital Regulation, *Journal of Banking Regulation*, Vol. 22, str. 308-318.
42. Milne, A. i Whalley, A. E. (2001) Bank Capital Regulation and Incentives for Risk-Taking, Cass Business School Research Paper, December. Dostupno na: http://papers.ssrn.com/sol3/papers.cfm?abstract_id=299319, [07.12.2023.]
43. Rime, B. (2001) Capital Requirements and Bank Behaviour: Empirical Evidence for Switzerland, *Journal of Banking and Finance*, Vol. 25, No. 4, str. 789-805.
44. Repullo, R. (2004) Capital Requirements, Market Power, and Risk-Taking in Banking, *Journal of Financial Intermediation*, Vol. 13, No. 2, str. 156-182.

45. Rochet, J. – C. (1992) Capital Requirements and the Behaviour of Commercial Banks, *European Economic Review*, Vol. 36, No. 5, str. 1137-1178.
46. Saadaoui, Z. (2011) Risk-Based Capital Standards and Bank Behaviour in Emerging and Developed Countries, *Journal of Banking Regulation*, Vol. 12, No. 2, str. 180-191.
47. Shrieves, R. E. i Dahl, D. (1992) The Relationship Between Risk and Capital in Commercial Banks, *Journal of Banking and Finance*, Vol. 16, No. 2, str. 439-457.
48. Stolz, S. M. (2007) *Bank Capital and Risk-Taking: The Impact of Capital Regulation, Charter Value, and the Business Cycle*. Kiel Studies. Springer-Verlag: Berlin Heidelberg.
49. Šútorová, B. i Teplý, P. (2014) EU Banks' Profitability and Risk Adjustment Decisions under Basel III, *Ekonomický časopis*, Vol. 62, No. 7, str. 667-691.
50. Van Roy, P. (2008) Capital Requirements and Bank Behavior, *International Journal of Central Banking*, Vol. 4, No. 3, str. 29-60.

CONSEQUENCES OF COMPLIANCE WITH CAPITAL REQUIREMENTS – PROTECTION AGAINST RISKS OR TRIGGER OF BANKS' RISK-TAKING BEHAVIOUR?

Full Professor Ana Kundid Novokmet, PhD

Faculty of Economics, Business and Tourism, University of Split

e-mail: ana.kundid.novokmet@efst.hr

ABSTRACT

Capital requirements are without a doubt the key stronghold of the prudential regulation of banks over the last 30 years. Persistency of this regulatory concept lies in its basic logic of enabling the free choice of business model, as well as speed of growth and risk level, while having adequate responsibility of bank owners. Namely, the balance between deregulation tendencies and goal of ensuring financial stability was attempted to be achieved by allowing the freedom to choose between bank business models as well as by tolerating diverse propensities in individual and overall bank risks, but within the boundaries of minimally required responsibility of bank shareholders. Complexity and high costs of complying with the capital requirements, their multiple amendments, while recording bank failures and financial crises, do not support further insistence on this regulatory instrument. However, there is no alternative as proposed solutions are usually radical, exclusive and insufficiently adjusted to the financial liberalization ideology. Thus, capital requirements last despite constant criticism of being inefficient or even counterproductive. To be more precise, capital requirements can trigger additional risk-taking behaviour of banks, which might be opposite of the safety and soundness goal in the business of banking. The paper aims to analyse theoretical and empirical strongholds of this phenomenon and answer the question whether capital requirements serve as a protection against the risks or add to bank risk-taking behaviour?²

Key words: capital requirements, risk-taking, banking regulation, moral hazard theory, capital buffer theory

JEL classification: G21, G28

² This paper is based on author's PhD dissertation i.e. the following reference: Kundid, A. (2013) *Pri-mjerenost kapitalnih zahtjeva za stabilnost bankarskog sektora*. Doktorska disertacija. Ekonomski fakultet: Split.

UTJECAJ BASELA IV NA KAPITALNE ZAHTJEVE ZA TRŽIŠNE RIZIKE

dr. sc. Bojan Tomić

Visoko učilište Effectus, Visoka škola za financije i pravo
e-mail: bojan.tomic2@gmail.com

prof. dr. sc. Saša Žiković

Sveučilište u Rijeci, Ekonomski fakultet
e-mail: sasa.zikovic@efri.uniri.hr

Lorena Jovanović, mag. oec.

Sveučilište u Rijeci, Ekonomski fakultet
e-mail: lorena.jovanovic@efri.uniri.hr

SAŽETAK

Basel IV industrijski je naziv za novu globalnu bankovnu regulatornu reformu čija je implementacija trebala započeti 2023. godine, a koja se nastavlja na ranije reforme Basel I, II i III. U četvrtom paketu reformi ponovno u fokus dolaze tržišni rizici i metodologija njihova izračuna. Glavna novina u mjerenju tržišnih rizika jest primjena nove vrste internog modela za ekstremne rizike i rizik tržišne nelikvidnosti pod nazivom Očekivani manjak u repu – Expected shortfall (ES). ES je mjera koja se fokusira na rizike koji se događaju kod ekstremnih tržišnih uvjeta. Rizična vrijednost – Value at Risk (VaR) fokusira se na maksimalni potencijalni gubitak na određenoj razini pouzdanosti (npr. 99 % te time u potpunosti ignorira 1 % najgorih gubitaka) dok ES mjeri prosječni gubitak upravo u ekstremnim gubiticima, čime predstavlja robusniju i konzervativniju mjeru rizika. U radu se analizira kvantitativni utjecaj regulativne promjene fokusa s VaR metodologije na ES metodologiju u formiranju kapitalnih rezervi u bankama. Dobiveni rezultati pokazuju značajne razlike između kapitalnih zahtjeva dobivenih na temelju Basel II regulative u odnosu na Basel III i IV, s time da su kapitalni zahtjevi kod Basela III i IV više nego dvostruko viši nego kod Basela II.

Ključne riječi: Basel IV, kapitalni zahtjevi, tržišni rizici, VaR, ES

JEL klasifikacija: C22, C54, G21, G32

1. UVOD

Baselski odbor za bankovnu superviziju, originalno zvan Odbor za bankarske regulative i nadzorne prakse, sa sjedištem u Banci za međunarodna poravnanja (Bank for International Settlements) u Baselu, Švicarska, osnovan je od strane guvernera centralnih banaka deset najrazvijenijih zemalja – G10 1974. godine. Glavni praktičan razlog osnivanja Baselskog odbora bila je ozbiljna kriza na intervalutarnom i bankovnom tržištu, koja je nastala propašću njemačke Herstatt banke. Formalni cilj osnivanja bilo je unaprjeđenje financijske stabilnosti uvođenjem standardiziranog i unificiranog nadzora banaka diljem svijeta, te da služi kao mjesto dogovora o koordinaciji i suradnji u pogledu supervizije banaka među zemljama članicama. Počevši s prvim Baselskim ugovorom (izdan 1975. godine) Baselski odbor postavio je sustav međunarodnih standarda za regulaciju banaka, najviše putem ključnih publikacija koje se odnose na adekvatnost bankovnog kapitala, koje se u praksi nazivaju Basel I, Basel II, Basel III te najnovije Basel IV. Iako, strogo formalno gledajući ovi standardi sami po sebi nisu obvezujući, oni se izdaju kada ih odobri Baselski odbor i kao takvi, članovi su obavezni prenijeti ih u vlastiti zakonodavni okvir vezan za regulaciju kreditnih institucija. U EU-u su Baselski standardi implementirani putem Smjernice o kapitalnim zahtjevima IV (CRDIV) i Uredbe o kapitalnim zahtjevima (CRR). Ova pravila vrijede i za Republiku Hrvatsku gdje su pretočena u Zakon o kreditnim institucijama (NN/ 159/13, 19/15, 102/15, 15/18, 70/19, 47/20, 146/20, 151/22).

Pri svom uvođenju još 2009. godine, kao odgovor na globalnu financijsku krizu iz 2008. godine, Basel III usredotočio se na povećanje stabilnosti financijskog sustava povećanjem kako količine tako i kvalitete jamstvenog kapitala (BCBS, 2005, 2009). Basel III izravno se nadovezuje na Basel I i Basel II u nastojanju da ojača sposobnost bankarskog sustava da se nosi s financijskim krizama, općenito poboljša upravljanje rizicima i promiče transparentnost. U odnosu na Basel II, Basel III je podigao kapitalne zahtjeve za redovni osnovni kapital (Tier-1) s 4 na 6 posto (BCBS, 2009). Među ostalim mjerama potrebno je istaknuti i zahtjeve o omjeru financijske poluge te dodatne zahtjeve za redovni osnovni kapital Tier-1 od 4,5 posto. Nakon što je Basel III stupio na snagu, centralne banke, kao i sam Baselski odbor željeli su ponovno razmotriti transparentnost i dosljednost u mjerenju rizika u svim pristupima, jurisdikcijama i bankama. U 2014. godini Baselski odbor počeo je izdavati prijedloge za reviziju standardiziranog pristupa kreditnom riziku (SA) i jednostavniji pristup za mjerenje operativnog rizika, koji dovode do prijedloga za novi standardizirani pristup mjerenju (SMA) za operativni rizik u 2016 (BCBS, 2016). Odbor je također započeo raspravu o pragovima modela agregiranog internog ocjenjivanja, za-

brinuti zbog varijabilnosti rizikom ponderirane imovine (RWA) koja proizlazi iz internih modela banaka. Baselski odbor je odmah nakon toga započeo pregovore o revidiranom okviru tržišnog rizika, s posebnim fokusom na knjigu trgovanja (FRTB), za koju je konačna norma objavljena u siječnju 2016. Ovaj set mjera kolokvijalno se naziva Basel IV, iako se ponegdje koristi i naziv Basel 3.1.

Basel IV imao je inicijalni „dobrovoljni“ rok za provedbu u 2015. godini. S vremenom je ovaj rok za primjenu sve više pomican te je za konačni datum za početak implementacije odabran 1. siječnja 2023. Za dio regulative koji se odnosi na tržišne rizike datum primjene je postavljen na 1. siječnja 2025. godine. S obzirom na trenutačne signale iz FED-a i ECB-a postaje sve očitiije da bi se i ovaj rok mogao pomaknuti.

Cilj ovog rada jest istražiti utjecaj regulatornih promjena reflektiranih u propisima Basel II, Basel III i Basel IV na kapitalne zahtjeve banaka. Najveći dio regulatornog utjecaja na samo formiranje kapitalnih rezervi proizlazi iz različitih metrika, tj. metodologija korištenih za izračun kapitalnih rezervi. Promatrajući čisto metodološki ovaj aspekt regulative razlika u kapitalnim rezervama svodi se na razlike u izračunu rizične vrijednosti (*Value at Risk* – VaR), kriznu rizičnu vrijednost (*Stressed Value at Risk* – SVaR) i očekivani manjak u repu (*Expected Shortfall* – ES). Svrha našeg istraživanja jest analizirati razlike u posljedicama primjene navedenih metodologija izračuna rizičnosti na formiranje kapitalnih rezervi za financijsku instituciju.

Ostatak ovog rada strukturiran je na sljedeći način: nakon uvoda slijedi drugo poglavlje pod nazivom Baselski ugovori o regulaciji banaka gdje je dat prikaz regulatornih reformi od svog početka do danas s posebnim naglaskom na regulaciju tržišnih rizika u bankama. Treće poglavlje pod nazivom Analiza posljedica izračuna tržišnog rizika za kapitalne zahtjeve temeljene na regulatornom okviru Basel II, Basel III i Basel IV donosi pregled izračuna kapitalnih zahtjeva u sva tri režima regulative te analizira razlike. Posljednje poglavlje zaključuje te daje preporuke za daljnja istraživanja.

2. BASELSKI UGOVORI O REGULACIJI BANAKA

1. BASEL I: ORIGINALNI UGOVOR O REGULACIJI MEĐUNARODNIH BANAKA

Od samog osnivanja fokus Baselskog odbora bio je primarno nadzor međunarodno aktivnih banaka, tj. dionika koji mogu izazvati ne samo lokalne već i re-

gionalne, pa čak i globalne posljedice. Odbor je u svom nastajanju reguliranja ovakvih banaka poseban naglasak stavio na stupanj adekvatnosti kapitala. Nakon kriza s neotplatom državnih obveznica u latinoameričkim zemljama početkom 1980-ih adekvatnost kapitala i način njegova izračuna postali su glavna tema u regulatornim krugovima. 80-ih godina pojavljuju se slične krize po južnoj Aziji te raste strah od globalne financijske krize velikih razmjera (BCBS, 1983). U svjetlu svih ovih događanja Baselski odbor odlučio je zaustaviti stalnu utrku za profitom i kontinuirano smanjenje adekvatnosti kapitala u bankarskim sustavima diljem svijeta. Kao jedino rješenje činilo se globalno usklađivanje mjerenja adekvatnosti bankovnog kapitala te razvoju metodologije rizičnog ponderiranja bilančnih i vanbilančnih stavki u aktivi banaka (BCBS, 1990).

Od samog početka bilo je jasno da ovakva vrste regulative ne može biti nacionalna jer bi kapital, kao i samo financijsko poslovanje, lako tražio mjesta s blažom regulativom i nižim standardima vezanim uz adekvatnost kapitala. Jedino bi međunarodni sporazum koji uključuje i najrazvijenije zemlje svijeta imao šansu izravnati konkurentsko okruženje u međunarodnom bankarstvu i tako osnažiti stabilnosti međunarodnog bankarskog sustava.

Metodološki razrađeni sustav za mjerenje adekvatnosti kapitala poznat u praksi kao Baselski kapitalni sporazum odobren je od strane guvernera zemalja G10 i javno je objavljen 1988. godine (BCBS, 1988).

Originalni Baselski sporazum zahtijevao je minimalni omjer kapitala prema rizikom ponderiranoj aktivi od 8 %. Godine 1993. Odbor je izdao priopćenje potvrđujući da banke zemalja G10 sa značajnim udjelom međunarodnog poslovanja ispunjavaju minimalne zahtjeve utvrđene u originalnom Baselskom sporazumu.

Sam sporazum kontinuirano prolazi kroz promjene i nikada nije ni bio namijenjen da bude statičan i nepromjenjiv. Sporazum je značajnije izmijenjen već 1991. godine kako bi jasnije razradio izdvajanja po rezervama za opće gubitke u kreditnom poslovanju (BCBS, 1991). 1995. godine Odbor je izdao još jednu izmjenu, kako bi se uzelo u obzir učinke netiranja kreditnih izloženosti banaka u derivatnim proizvodima, a dodatno su učinci netiranja i način njihova priznavanja definirani 1996. godine (BCBS, 1995).

Nakon početnog fokusa na kreditni rizik u bankovnim knjigama Odbor je počeo ozbiljnije promatrati i ostale rizike kojima su izložene banke. U prvom redu to je bio tržišni rizik, a kasnije i operativni rizik. Godine 1996. Odbor je konačno izdao smjernice za upravljanje tržišnim rizicima u dokumentu pod

nazivom „Amandman na Baselski sporazum za uključivanje tržišnih rizika“, koji je stupio na snagu 1997. godine (BCBS, 1996). Ovaj ključni amandman osmišljen je kako bi unutar postojeće regulative uključio i kapitalne zahtjeve za tržišne rizike. Pod tržišnim rizicima smatra se rizik nepovoljnih kretanja tržišne vrijednosti portfelja, uslijed tržišnih kretanja, tijekom razdoblja potrebnog za likvidaciju transakcija. Baselski odbor pod tržišnim rizicima podrazumijeva: pozicijski rizik, kamatni rizik, devizni rizik te robni rizik.

Apsolutna novina u izračunu rizičnosti imovine i kapitalnih zahtjeva, koju je uveo ovaj Amandman bila je dozvola bankama da u izračunu rizikom ponderirane imovine koriste interne modele procjene rizika temeljene na *Value at Risk* (VaR) metodologiji. Kako bi banka umjesto standardiziranog pristupa mogla koristiti interne modele morala je dobiti odobrenje svog nacionalnog regulatora.

2. BASEL II: UVOĐENJE TRI STUPA BANKOVNE STABILNOSTI

Baselski je odbor 1999. godine izdao novi prijedlog regulative adekvatnosti kapitala kako bi zamijenio originalni Baselski sporazum iz 1988. godine. Ova inicijativa konačno je finalizirana 2004. godine objavom novog kapitalnog sporazuma koji je u praksi prozvan Basel II. Novi regulatorni okvir sastojao se od tri stupa regulacije (BCBS, 2005):

- 1) minimalni kapitalni zahtjevi kojima se ciljalo razviti i proširiti postojeće standarde postavljene u izvornom sporazumu
- 2) regulatorni pregled adekvatnosti kapitala banke i standardiziranje procjene adekvatnosti internih modela mjerenja rizika
- 3) naglasak na transparentno objavljivanje informacija kao poluge za jačanje tržišne discipline i poticanje odgovornih bankovnih praksi

Novi sporazum formuliran je tako da poboljša način na koji regulativa obuhvaća rizike s kojima se susreću banke u svom poslovanju. Jedan od važnih razloga nastanka Basela II bile su i brojne financijske inovacije na tržištima koje su nastale tijekom 90-ih godina.

Jedan od glavnih izazova s kojima se susreo Baselski odbor kod Amandmana za tržišne rizike iz 1996. godine, kao i sa samim Baselom II bilo je pitanje regulatorne jurisdikcije, tj. međunarodne banke morale su u svakoj državi u kojoj su poslovale dobiti od lokalnog regulatora odobrenje za korištenje internog modela za procjenu rizika. Kako bi se pokušao riješiti ovaj problem 2007.

godine izdane su Smjernice o suradnji regulatora i mehanizmima raspodjele u kontekstu naprednih pristupa mjerenju rizika (BCBS, 2007).

3. BASEL III: ODGOVOR NA FINACIJSKU KRIZU 2007. - 2009.

Čak i prije financijske krize 2007. godine te prvo propasti investicijske banke Bear Stearns pa zatim Lehman Brothersa sve su glasnjiji bili pozivi u akademskoj i stručnoj javnosti za reformom Basel II okvira jer su se počele otkrivati slabosti metodologije izračuna kapitalnih rezervi, ali i slabosti same VaR metodologije izračuna rizičnosti.

Potrebno je priznati da je Baselski odbor promišljao o ovim slabostima i povezanim rizicima već i prije same krize pa je tako npr. izdao smjernice za banke pod nazivom „Načela za upravljanje likvidnosnim rizikom“ (BCBS, 2008) istoga mjeseca kada je propao Lehman Brothers. Godine 2009. Baselski odbor izdao je dodatni paket mjera i smjernica kako bi ojačao Basel II, posebno u vezi s tretmanom sekuritizirane imovine, vanbilančnih pozicija i derivativnim izloženostima u trgovinskoj knjizi. Sve ove mjere bile su izravan odgovor na financijsku krizu koja je jasno istaknula slabosti Basel II ugovora. U rujnu 2010. godine, guverneri centralnih banaka pri baselskom odboru objavili su nove minimalne kapitalne standarde. To je slijedilo nakon postignutog sporazuma u srpnju u vezi s općim oblikovanjem paketa reformi kapitala i likvidnosti, sada poznatog kao „Basel III“. U studenom 2010., nove standarde kapitala i likvidnosti pod kolokvijalnim nazivom Basel III podržali su lideri zemalja G20, te je paket mjera konačno odobren na sastanku Baselskog odbora u prosincu 2010. godine.

Formalno je nova revizija standarda objavljena od strane Baselskog odbora u prosincu 2010. godine u dva dokumenta pod nazivom „Basel III: Međunarodni okvir za mjerenje, standarde i praćenje likvidnosnih rizika“ (BCBS, 2010a) i „Basel III: Globalni regulatorni okvir za otpornije banke i bankarske sustave“ (BCBS, 2010b).

Basel III revidira tri stupa regulacije koja su definirana još pod Baselom II, ali im i značajno proširuje krug djelovanja. Većina reformi postupno se uvodila u razdoblju od 2013. do 2019. godine. Osnovne preinake u originalnim regulatornim stupovima očituju se u sljedećim područjima:

1. stroži zahtjevi za kvalitetu i visinu regulatornog kapitala, posebno jačanje ključne uloge dioničkog kapitala

2. dodatni sloj dioničkog kapitala, tj. sloj za očuvanje kapitala koji, kada se prekorači, ograničava isplate kako bi se održala minimalna propisana razina potrebnog kapitala
3. kontraciklični kapitalni sloj koji postavlja ograničenja na sudjelovanje banaka u kreditnim ekspanzijama s ciljem smanjenja gubitaka u kriznim vremenima
4. omjer financijske poluge, tj. minimalni iznos kapitala u odnosu na svu bankovnu imovinu, kao i izvanbilančne izloženosti bez obzira na njihov rizični ponder
5. omjer pokrića likvidnosti (*Liquidity Coverage Ratio* - LCR), namijenjen osiguranju dovoljne količine likvidnih sredstava za pokrivanje potreba za financiranjem tijekom razdoblja od 30 dana stresa
6. omjer stabilnog financiranja neto (*Net Stable Funding Ratio* - NSFR), namijenjen rješavanju nerazmjera dospijeca na razini cjelokupne bilance
7. dodatni kapitalni zahtjevi za sistemski važne banke, uključujući dodatnu sposobnost apsorpcije gubitaka i aranžmani za pojačani nadzor i rješavanje prekograničnih situacija

4. BASEL IV: ZAVRŠNA FAZA BASELA III

Baselski odbor završio je svoje reforme u sklopu regulatornog paketa mjera Basel III 2017. godine, objavljivanjem novih standarda za izračunavanje kapitalnih zahtjeva za kreditni i operativni rizik (BCBS, 2017). Konačne reforme uključuju i revidiran odnos financijske poluge, dodatak na financijsku polugu za globalno sistemski važne banke te ograničenje na interne modele u kojem se određuje u kojoj mjeri banke mogu koristiti interne modele u odnosu na standardizirani pristup zbog smanjenja kapitalnih zahtjeva. Jedan od ključnih ciljeva Basel III izmjena bio je smanjenje pretjerane varijabilnosti rizikom ponderirane imovine (*risk-weighted assets* - RWA). Tijekom globalne financijske krize, javnost i regulatori izgubili su povjerenje u bankovne interne modele te posljedično i stope adekvatnosti kapitala. Basel III napravljen je kako bi se vratilo povjerenje u izračunavanje rizičnosti, RWA, a samim time i adekvatnosti kapitala poboljšanjem osjetljivosti na rizik standardiziranih pristupa za kreditni i operativni rizik, ograničavajući interni pristup izračunu rizičnosti i dopunjujući postojeći okvir revidiranim omjerom financijske poluge. Ove bi reforme trebale riješiti nedostatke Basela II te pružaju regulatornu osnovu za otporniji bankarski sustav.

Za vrijeme čekanja na konačan rok za implementaciju Basela III, Baselski odbor nastavio je prilagođavanje njegovih odredbi. Zaključne odredbe Basela III, a koje su donijete u razdoblju od 2016. do 2019. godine (BCBS, 2016, 2017, 2019) u financijskoj se zajednici nazivaju „Baselom IV“. Basel IV počeo je s primjenom 1. siječnja 2023..

Vezano za tržišni rizik, tj. mjerenje i upravljanje tržišnim rizikom u trgovinskoj knjizi banke pristup internih modela iz siječnja 2016. i siječnja 2019. godine (BCBS, 2016, 2019) propisuje detaljan postupak odobravanja modela kako bi osigurao da se interni modeli koriste samo tamo gdje regulator ima potpuno povjerenje u njihovu valjanost. Ovaj pristup također je koncipiran s ciljem boljeg obuhvata kreditnih rizika povezanih s knjigom trgovanja, rizika od ekstremnih događaja te rizika nelikvidnosti. Zaključna faza Basela III, tj. Basel IV napušta koncept izračuna rizičnosti imovine temeljen na VaR-u te se sada oslanja na set od 3 indikatora, ali čiju osnovicu čini očekivani manjak u repu (*Expected shortfall* - ES). Osnova za izračun kapitalnih zahtjeva za tržišne rizike prema regulativi Basel IV sastoji se od:

- 1) očekivanog manjka u repu (*Expected Shortfall* - ES), a koristi se za određivanje kapitalnih zahtjeva za tržišne rizike kod onih čimbenika tržišnog rizika gdje postoji dovoljna količina trgovinskih podataka
- 2) faktora rizika koji se ne može modelirati (*Non-Modellable Risk Factor* - NMRF), a koristi se za faktore tržišnog rizika za koje ne postoji dostatna količina trgovinskih podataka pa se stoga smatraju neprikladnim za modeliranje
- 3) kapitalnog zahtjeva za kreditni rizik (*Default Risk Capital* - DRC), koji predstavlja dodatni kapitalni zahtjev za pozicije s rizikom neplaćanja kod kreditnih i vlasničkih pozicija.

Cjelokupni kapitalni zahtjev za tržišne rizike prema ovom pristupu jest zbroj kapitalnih zahtjeva za svaku od ovih triju navedenih komponenti. Sukladno pravilima objavljenim 2019. godine (BCBS, 2019) regulatorno odobrenje za upotrebu internog modela daje se na razini trgovinskih odjela banaka. Trgovinski odjel banke, kako bi imao pravo koristiti interne model u svrhu izračuna kapitalnih zahtjeva za tržišne rizike, mora zadovoljiti dva ključna testa:

1. priznavanje dobitaka i gubitaka (*profit & loss* - P&L) – ovaj test utvrđuje uključuje li interni model sve rizike koji utječu na dnevne dobitke i gubitke trgovinskog odjela

2. testiranje (backtesting) – ovaj test ocjenjuje preciznost internog modela u procjeni rizika kako bi pokrio gubitke u trgovanju.

Trgovinski odjeli koji ne prođu ova dva testa moraju se osloniti na standardizirani pristup za izračun kapitalnih zahtjeva.

Ključna razlika u Baselu IV u odnosu na prijašnje regulatorne okvire jest potpuni odmak od *Value at Risk* (VaR) metodologije koja se sada zamjenjuje puno robusnijom *Expected Shortfall* (ES) metodologijom. Primjena *Expected Shortfall* (ES) metodologije posjeduje dvije ključne karakteristike koje rješavaju osnovne i dobro poznate nedostatke *Value at Risk* (VaR) metodologije:

1. ES obuhvaća ekstremne rizike u repu distribucije koje VaR ne uzima u obzir.
2. U sklopu mjerenja rizika pomoću ES-a Basel propisuje različite horizonte likvidnosti za različite čimbenike rizika, uzimajući u obzir vrijeme potrebno za likvidaciju trgovinske pozicije bez značajnog utjecaja na tržišne cijene u kriznim uvjetima. Ovakav pristup koji je primijenio Basel povećava kapitalne zahtjeve za manje likvidnu imovinu.

Revizija za tržišne rizike iz 2019. godine svjesno ograničava koristi diverzifikacije u određivanju kapitalnih zahtjeva. Ovo je učinjeno namjerno kako bi se uzelo u obzir da tijekom kriznih razdoblja korelacija različitih vrste financijske imovine teži ka snažnoj pozitivnoj korelaciji te se time u dobroj mjeri gube bilo kakvi učinci pretpostavljene diverzifikacije. Izmjena iz 2019. godine to čini na vrlo jednostavan način tako da se ukupni kapitalni zahtjev putem *Expected Shortfalla* (ES) računa kao prosjek između dviju mjera:

1. „neograničenog“ ES-a koji uzima u obzir koristi diverzifikacije za sve vrste imovine
2. „ograničenog“ ES-a koji ne uzima u obzir koristi diverzifikacije te je samo zbroj odvojenih izračuna ES-a za svaku klasu rizika.

Za razliku od prethodnih pristupa koji su omogućavali bankama da modeliraju sve rizike u svom trgovinskom portfelju, revidirani okvir prepoznaje značajnu neizvjesnost u modeliranju rizika za imovine koje imaju ograničene povijesne tržišne podatke. Čimbenici rizika, tj. vrste imovine, koji nemaju dovoljno tržišnih podataka smatraju se nepodobnim za klasično modeliranje putem VaR-a ili ES-a.

3. ANALIZA POSLJEDICA IZRAČUNA TRŽIŠNOG RIZIKA ZA KAPITALNE ZAHTEJEVE TEMELJENE NA BASEL II, BASEL III I BASEL IV REGULATORNOM OKVIRU

Izračun kapitalnih zahtjeva za tržišne rizike na temelju internog pristupa u Baselu II temelji se na *Value at Risk* (VaR) metodologiji. VaR predstavlja jedinstvenu, sumarnu, statističku mjeru mogućih gubitaka na vrijednost trgovinskog portfelja, koji mogu nastati uslijed „normalnog“ kretanja tržišta. Gubici koji prelaze vrijednost VaR-a događaju se samo uz određenu vjerojatnost. Mjerenje tržišnih rizika putem VaR-a odvija se putem triju glavnih načina mjerenja (Žiković, 2010), a to su:

1. neparametarski pristup
2. parametarski pristup
3. hibridni pristup.

Ova tri pristupa VaR-a se suštinski značajno razlikuju te zbog toga često daju različite rezultate. Zajedničko svim ovim pristupima jest praćenje kretanja malog broja faktora rizika, kao što su npr. kamatna stopa, valutni tečajevi, volatilnosti itd. Sva tri pristupa izračuna VaR-a koriste povijesnu distribuciju promjena cijena na tržištu kako bi odredili odgovarajuću distribuciju za dobivene podatke (Žiković, 2008a, 2008b). Sve tri metode suočene su s izazovom odabira vremenskog horizonta za korištenje povijesnih podataka. Problem izbora vremenskog horizonta proizlazi iz nemogućnosti postizanja istodobno dvaju suprotnih ciljeva koji se žele ostvariti. S jedne strane, želi se uzeti dovoljno dugo povijesno razdoblje kako bi dobiveni podaci obuhvatili rijetke i ekstremne događaje koji često uzrokuju ozbiljne gubitke. S druge strane, s obzirom na to da se VaR-om želi predvidjeti buduću distribuciju povrata, nužno je koristiti najnovije tržišne podatke koji odražavaju najnovija kretanja na tržištima (Kritzman, Rich, 2002). S obzirom na trenutačnu nemogućnost potpunog usklađivanja ova dva ekstrema, važno je pronaći odgovarajući kompromis. Osim problema s vremenskim horizontom nedostaci VaR-a kao metodologije izračuna rizičnosti trgovinskih pozicija su brojni, ali glavna dva problema VaR-a jesu:

1. VaR u potpunosti zanemaruje gubitke koji se događaju u repu distribucije (Žiković, Pečarić, 2010a).
2. Artzner *et al.* (1999) definirali su karakteristike koje svaka valjana mjera rizika mora zadovoljavati. Mjere koje zadovoljavaju postavljene aksiome

nazivaju se „koherentne” mjere rizika“. VaR ne zadovoljava uvjet subaditivnosti te time nije prava, tj. koherentna mjera rizika.

Regulativa Basel III, s obzirom na to da se oslanja na negativne posljedice i loše rezultate primjene VaR-a tijekom globalne financijske krize, pokušava unaprijediti koncept izračuna VaR-a i uvodi u terminologiju SVaR, tj. krizni VaR (*Stressed Value at Risk*). SVaR pokušava učiniti VaR primjenjivijim tijekom kriznih razdoblja. Budući da se VaR izračunava na temelju najaktualnijih povijesnih podataka (trenutačno stanje na tržištu) te ako je trenutačno tržište u uzlaznoj fazi, VaR ne može uzeti u obzir tržišna događanja iz kriznih razdoblja (bilo prethodna ili buduća), a koja u biti predstavljaju stvarni rizik za svakog ulagača (Žiković, 2017). SVaR pokušava riješiti ovaj problem tako da zadrži originalni VaR pristup izračunu tržišnog rizika, ali za bazu podataka ne koristi aktualno stanje na financijskom tržištu već se temelji na kriznom scenariju, tj. na podacima iz vremena relevantne financijske krize. Ova izmjena trebala bi omogućiti SVaR-u da pruži realniju mjeru rizika trgovinskog portfelja tijekom tržišnih kriza. SVaR metode temeljene na scenario analizi uključuju stvaranje specifičnog kriznog scenarija koji je konstruiran tako da odražava tržišno okruženje koje karakterizira ozbiljna financijska kriza. Najraširenije SVaR metode izračuna temelje se većinom na Monte Carlo simulaciji ili povijesnoj simulaciji, tj. na korištenju povijesnih podataka iz kriznih razdoblja za procjenu rizičnosti aktualnog bankovnog portfelja.

Glavna prednost kriznog VaR-a (SVaR) u odnosu na *Value at Risk* (VaR) leži u njegovoj sposobnosti pružanja realističnijeg mjerenja rizika tijekom tržišnih kriza. Ova karakteristika dobiva poseban značaj za banke jer im omogućuje realniju sliku u stvarno stanje na tržištu te da na vrijeme reagiraju na nastajuće financijske probleme, bilo likvidacijom pojedinih pozicija iz aktive ili njihovim *hedgingom*. Korištenje SVaR-a također doprinosi boljem razumijevanju potencijalnog utjecaja tržišnog stresa na bankovne portfelje, omogućujući im prilagodbu strategija upravljanja rizicima prema potrebi. Unatoč tim prednostima, izazovi se pojavljuju tijekom izračuna i implementacije SVaR-a, posebice u situacijama gdje postoje ograničeni podaci o ekstremnim tržišnim događajima, dok je sam izračun SVaR-a, isključujući bazu podataka koje koristi, identičan klasičnom izračunu VaR-a. Međutim, jedna od slabih točaka SVaR-a upravo leži u njegovoj ovisnosti o statističkom modelu za procjenu vjerojatnosti ekstremnih događaja, što znači da možda neće precizno obuhvatiti potencijalne utjecaje ekstremnih događaja. Također, teškoća može nastati u točnom određivanju kriznog scenarija koji će se koristiti za procjenu SVaR-a, što može rezultirati nepouzdanim procjenama.

Basel IV ili ponekad zvan Basel 3.1. zapravo je zadnja faza implementacije Basela III. Basel IV čini značajan odmak od prethodne regulacije vezane za interne modele mjerenja rizika i u potpunosti napušta korištenje VaR-a i pokušaje reformacije VaR-a, kao što to čini SVaR. U skladu s pozivima akademije Baselski odbor konačno uvažava da se svi problemi vezani uz samu VaR metodologiju ne mogu riješiti na sustavan i logičan način te u skladu s nalazima Artzner *et al.* (1999) odlučuje koristiti novu „koherentnu“ mjeru rizika pod nazivom „očekivani manjak u repu“ (*Expected shortfall* - ES) ili uvjetna rizična vrijednost (*Conditional VaR* - CVaR) ili očekivani gubitak u repu (*Expected tail loss* - ETL). Sva tri naziva odnose se na istu metriku rizika. ES pruža informacije i o vjerojatnosti i veličini potencijalnih gubitaka u repu distribucije imovine. ES predstavlja očekivanu vrijednost gubitaka iznad razine vjerojatnosti VaR-a, tj. mjeri prosječni gubitak u situacijama kada je gubitak veći od onog što VaR predviđa (Žiković, 2008c).

ES je vrlo korisna i intuitivna mjera rizika koja se primarno fokusira na ekstremne događaje, tj. događaje u repu distribucije. Međutim, poput ostalih mjera rizika, ES ima svoja ograničenja koja treba uzeti u obzir. Ključni izazov u korištenju ES-a leži u potrebi procjene distribucije portfelja u repu, što može biti izazovno, posebno kada se radi o složenim ili nelikvidnim instrumentima s ograničenim povijesnim podacima (Žiković, Pečarić, 2010b, Žiković, Vlahinić-Dizdarević, 2011). Osim toga, važno je naglasiti da ovisnost o izboru razine vjerojatnosti VaR-a predstavlja dodatni izazov s ES-om, pri čemu rezultati mogu značajno varirati ovisno o odabranoj razini vjerojatnosti (Žiković, Tomas Žiković, 2016). Stoga, upravitelji rizika trebaju pažljivo razmotriti odgovarajući prag za svoj portfelj, osigurati da je usklađen s njihovom tolerancijom na rizik te zadovoljava regulatorne zahtjeve.

1. EMPIRIJSKA USPOREDBA KAPITALNIH ZAHTJEVA ZA TRŽIŠNI RIZIK

U ovom dijelu rada empirijski će se analizirati utjecaj promjena regulative koja se odnosi na interne modele za procjenu tržišnih rizika iz Basela II, Basela III i konačno Basela IV na procjenu rizičnosti imovine i konačno na same kapitalne zahtjeve za tržišni rizik.

Analiza započinje s izračunom očekivanog prinosa, standardne devijacije i korelacijske matrice portfelja banke. Radi pojednostavljenja prikaza može se pretpostaviti da se trgovinska knjiga banke sastoji od triju vrsta imovine i to: visokolikvidne dionice s hrvatskog tržišta kapitala (npr. Podravka), dionice

niže likvidnosti s hrvatskog tržišta kapitala (npr. Plava laguna) i intervalutnog para CHF/EUR. U Tablici 1. dati su godišnji i dnevni prosječni prinosi i standardne devijacije navedene imovine. U nastavku rada navedena imovina bit će označena slovima A (dionice Podravke), B (dionice Plave lagune) i C (valutni par CHF/EUR).

Tablica 1. Godišnji i dnevni prinosi na bankin portfelj investicija u trgovinskoj knjizi banke

Portfelj	Udio	Godišnji prinos	Godišnja standardna devijacija	Dnevni prinos	Dnevna standardna devijacija
PODR-R-A (A)	33,3 %	14 %	77 %	0,056 %	0,306 %
PLAG-R-A (B)	33,3 %	10 %	82 %	0,040 %	0,325 %
CHF/EUR (C)	33,3 %	6 %	39 %	0,024 %	0,155 %
Ukupno		10 %	66 %	0,04 %	0,26 %

Izvor: autorov izračun

Godišnja srednja vrijednost prinosa na ovaj trgovinski portfelj iznosi 10 %, a nediverzificirana volatilnost, mjerena standardnom devijacijom portfelja, na godišnjoj razini iznosi 66 %. Dnevna srednja vrijednost prinosa na portfelj iznosi 0,04 %, dok je nediverzificirana standardna devijacija portfelja na dnevnoj razini 0,26 %. U Tablici 2. dana je korelacijska matrica.

Tablica 2. Korelacijska matrica imovine koja se vodi u trgovinskoj knjizi banke

Korelacijska matrica	A	B	C
A	0,59290	0,00011	-0,00042
B	0,00011	0,67240	0,00290
C	-0,00042	0,00290	0,15210

Izvor: autorov izračun

Na temelju volatilnosti i kovarijanci između imovine predstavljene u Tablici 2. jednostavno je izračunati varijancu (standardnu devijaciju) portfelja od triju vrsta imovine na način:

$$\sigma^2_{port} = w_A^2 \sigma_A^2 + w_B^2 \sigma_B^2 + w_C^2 \sigma_C^2 + 2w_A w_B Cov(R_A, R_B) + 2w_A w_C Cov(R_A, R_C) + 2w_B w_C Cov(R_B, R_C) \quad (1)$$

Diverzificirana volatilnost (varijanca) portfelja sastavljenog od jednakih dijelova imovine u ukupnom portfelju, na godišnjoj razini, iznosi 0,158, tj. da je godišnja standardna devijacija 39,76 %. Budući da je godišnja nediverzificirana

standardna devijacija 66 %, a diverzificirana (uzimajući u obzir kovarijance među različitim imovinom) 39,76 % očit je doprinos diverzifikacije smanjenju rizičnosti portfelja, pri čemu je standardna devijacija smanjena za čak 26,24 postotna boda, tj. za gotovo 40 %. Dnevna diverzificirana standardna devijacija portfelja iznosi 0,16 % (39,76 % / 252).

Nakon što su određeni ovi statistički parametri koji su potrebni za sve tri analizirane regulative u nastavku će se izračunati rizičnost imovine i kapitalni zahtjevi.

BASEL II

Prema regulativi Basel II za izračunavanje kapitalnog zahtjeva potrebno je izračunati vrijednost VaR-a pri razini pouzdanosti od 99 % pouzdanosti i razdoblju od 10 dana držanja. Ako VaR model zadovoljava testiranje uspješnosti prognoziranja iznos rizika množi se s koeficijentom 3 i dobiveni umnožak predstavlja kapitalni zahtjev za tržišne rizike.

Budući da cilj ovog rada nije testiranje valjanosti različitih VaR i ES modela nego prikaz posljedica različitih metodologija izračuna na kapitalne zahtjeve, koristit će se najjednostavniji model VaR, tj. VCV VaR (varijanca kovarijanca VaR). Formula za izračun VCV VaR-a glasi:

$$VaR_{T,cl} = \alpha_{cl}\sqrt{N}\sigma_r - N\mu \quad (2)$$

gdje je:

α_r - normalizirana Z vrijednost koja odgovara razini vjerojatnosti ispod pretpostavljene teorijske distribucije (zbog svoje jednostavnosti najčešće je korištena Gaussova – normalna distribucija)

cl - razinu vjerojatnosti

N - vrijeme držanja imovine

μ_r - prosječni prinos

Uobičajena pretpostavka u upravljanju rizicima jest da prosječni dnevni prinos iznosi nula te se zbog VCV VaR može pisati kao:

$$VaR_{T,cl} = \alpha_{cl}\sqrt{N}\sigma_r - N\mu \quad (3)$$

$$VaR_{10,0,99} = 2.326 \times \sqrt{10} \times 0,0016 = 1,16 \% \quad (4)$$

VaR s 99 % vjerojatnosti i 10 dana držanja iznosi: 1,16 %

Kapitalni zahtjev (C_A) prema Baselu II, uz standardni multiplikator (m_c) od 3 iznosi 3,48 %:

$$C_A = \max\{VaR_{t-1}; m_c \times VaR_{avg}\} = 3 \times 1,16 \% = 3,48 \% \quad (5)$$

BASEL III

Basel III nije metodološki mijenjao VaR, ali je uveo promjene u sam način izračuna VaR-a. U potpunosti je promijenjena baza podataka koja se koristi za izračun VaR-a. Umjesto korištenja posljednjih 250 opažanja SVaR pristup zahtijeva korištenje podataka iz kriznog razdoblja, koji se smatra relevantnim za sastav bankovnog portfelja i njezino poslovanje. Zbog ove promjene u korištenim podacima za procjenu VaR-a razvio se upravo i novi naziv za ovu vrstu mjerenja rizika, tj. krizni VaR (SVaR). Ova modifikacija VaR-a, koju je predložio Baselski odbor kako bi riješio najveći problem neadekvatnosti, VaR za poslovanje u kriznim situacijama nije dao željene rezultate te nije bio toplo prihvaćen ni od industrije ni od akademske zajednice.

Dodatni podatak koji je potreban za izračun SVaR-a jest omjer između krizne i sadašnje volatilnosti. Ako se pretpostavi da je volatilnost u kriznom razdoblju za 50 % veća od sadašnje tržišne volatilnosti, omjer (alfa) iznosi 1,5. Slično kao kod Basela II, izračun kapitalnog zahtjeva prema Baselu III počiva na koeficijentu u iznosu od 3 pomnoženim sa sumom VaR-a i SVaR-a:

Uz 99 % vjerojatnosti i 10 dana držanja SVaR iznosi:

$$\sigma_{SVaR} = \sigma_s \times \alpha = 0,0016 \times 1,5 = 0,0024 = 0,24 \% \quad (6)$$

$$SVaR_{10,0,99} = 2,326 \times \sqrt{10} \times 0,0024 = 0,0174 = 1,74 \% \quad (7)$$

Prema Baselu III kapitalni bi zahtjev (C_A) uz 99 % vjerojatnosti i 10 dana držanja iznosio 8,70 %:

$$C_A = \max\{VaR_{t-1}; m_c \times VaR_{avg}\} + \max\{SVaR_{t-1}; m_c \times SVaR_{avg}\} = 3 \times 1,16 + 3 \times 1,74 \% = 8,70 \% \quad (8)$$

BASEL IV

Sukladno pravilima Basel IV razina vjerojatnosti za koju se izračunava ES iznosi 97,5 %, što čini još jedan odmak od Basela II i III gdje su se VaR i SVaR računali uz 99-postotnu vjerojatnost. Ponovno kao i u slučaju izračuna VaR-a i SVaR, s obzirom na to da cilj ovog rada nije ispitivanje valjanosti i podobnosti

pojedinih modela mjerenja rizika, koristit će se jednostavan parametarski izračun ES-a uz pretpostavku normalne distribucije. Formula za parametarski ES s normalnom distribucijom glasi:

$$ES_{\alpha} = \mu + \sigma \frac{\varphi(\Phi^{-1}(\alpha))}{1-\alpha} \quad (9)$$

gdje je $\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$ standardni pdf normalne distribucije, $\Phi(x)$ je cdf normalne distribucije što $\Phi^{-1}(x)$ čini kvantilom normalne distribucije.

Prvo će se izračunati ES za svaku pojedinačnu vrstu imovine (A, B i C) za vrijeme držanja od jednog dana:

$$ES_{A,1,0,975} = 0,00056 + 0,00306 \frac{\varphi(\Phi^{-1}(0,975))}{1-0,975} = 0,77 \% \quad (10)$$

$$ES_{B,1,0,975} = 0,00040 + 0,00400 \frac{\varphi(\Phi^{-1}(0,975))}{1-0,975} = 0,80 \% \quad (11)$$

$$ES_{C,1,0,975} = 0,00024 + 0,00240 \frac{\varphi(\Phi^{-1}(0,975))}{1-0,975} = 0,39 \% \quad (12)$$

Basel IV je uveo pravilo da se sva imovina likvidnosno ponderira, tj. podijeli na likvidnosne horizonte (LH):

Tablica 3. Likvidnosni horizonti za izračun ES-a prema kategorijama imovine

j	
1	10
2	20
3	40
4	60
5	120

Izvor: BCBS, 2019

U ovdje analiziranom portfelju imovine od koje se portfelj sastoji raspoređena je kao: Podravka - dionice visoka kapitalizacija (A) – 1. kategorija (10 dana), Plava laguna - dionice niska kapitalizacija (B) – 2. kategorija (20 dana), volatilitnost valutnog para CHF/EUR (C) – 3. kategorija (40 dana). Budući da redovna dionica Podravke (PODR-R-A) spada u vodeće tržište na ZSE svrstana je u kategoriju 1 (10 dana), redovna dionica Plave lagune (PLAG-R-A) spada u redovito tržište na ZSE te je time svrstana u kategoriju 2 (20 dana), Volatilnost deviznog tečaja CHF/EUR spada u kategoriju 3 (40 dana).

Na temelju gore izračunatih ES vrijednosti za svaku vrstu imovine te uzimajući u obzir likvidnosne horizonte za pojedine vrste imovine izračunat će se likvidnosno ograničeni ES:

$$ES_L = \sqrt{(ES_T(P))^2 + \sum_{j \geq 2} \left(ES_T(P, j) \sqrt{\frac{(LH_j - LH_{j-1})}{T}} \right)^2} \quad (13)$$

Prva transformacija koju je potrebno provesti jest vremenska transformacija jer se prethodne ES vrijednosti odnose na vremenski horizont od jednog dana. Transformacija se vrši pomoću pravila kvadrata vremena, što daje:

$$ES_{A,10,0,975} = \sqrt{10} \times ES_{A,1,0,975} = \sqrt{10} \times 0,77 = 2,43 \% \quad (14)$$

$$ES_{B,10,0,975} = \sqrt{10} \times 0,80 = 2,53 \% \quad (15)$$

$$ES_{C,10,0,975} = \sqrt{10} \times 0,39 = 1,22 \% \quad (16)$$

Sljedeći korak jest izračun ograničenog ES-a, tj. ES mjere koja ne uzima u obzir učinak diverzifikacije:

$$ES_L = \sqrt{(ES_{A,10})^2 + \left(ES_{B,10} \times \sqrt{\frac{20-10}{10}} \right)^2 + \left(ES_{C,10} \times \sqrt{\frac{40-20}{10}} \right)^2} = 3,91 \% \quad (17)$$

Basel IV propisuje da se ES za trgovinski portfelj izračunava koristeći ograničeni skup čimbenika rizika (ESR,S) koji se temelji na jednogodišnjem razdoblju najvećeg tržišnog stresa dostupnog unutar vremena promatranja. ESR,S uvećava omjerom trenutnog ES-a dobivenog korištenjem svih čimbenika rizika ESF,C i trenutnog ES-a izračunatog korištenjem ograničenog skupa čimbenika ESR,S.

$$ES = ES_{R,S} \times \frac{ES_{F,C}}{ES_{R,C}} \quad (18)$$

Omjer između ESF,S i ESR,S u ovom primjeru iznosi 1,5 pa je iznos ograničenog ES-a:

$$ES_{ogr} = 3,91\% \times 1,5 = 5,87 \% \quad (19)$$

Nakon izračuna ograničenog ES-a potrebno je izračunati neograničeni ES, tj. uzeti u obzir koristi diverzifikacije unutar portfelja. Korelacijska matrica je zapravo ista kao i u Tablici 2. osim što je korigirana za 10-dnevni ES svakog elementa, no kovarijance ostaju jednake:

Tablica 4. Korelacijska matrica 10-dnevnog ES-a imovine u portfelju

Korelacijska matrica	A	B	C
A	0,00059	0,00011	-0,00042
B	0,00011	0,00064	0,00290
C	-0,00042	0,00290	0,00030

Izvor: autorov izračun

Varijanca portfelja koji se sastoji od A, B i C imovine s jednakim pojedinačnim ponderima iznosi 0,00075, a budući da je standardna devijacija osnova za ES, neograničeni ESR,S iznosi 2,73 %, a neograničeni ES 4,1 %:

$$ES_{neogr} = 2,73 \% \times 1,5 = 4,10 \% \quad (20)$$

Agregatni kapitalni zahtjev za rizične faktore koji se mogu modelirati (IMCC) izračunava se kao ponderirana suma ograničenog i neograničenog ES-a:

$$IMCC = \rho(IMCC(C)) + (1 - \rho)(\sum_{i=1}^R IMCC(C_i)) \quad (21)$$

$$IMCC(C) = ES_{R,S} \times \frac{ES_{F,C}}{ES_{R,C}}; IMCC(C_i) = ES_{R,S,i} \times \frac{ES_{F,C,i}}{ES_{R,C,i}} \quad (22)$$

Aktualni Basel IV postavlja ρ na 0.5, tj. pola značaja daje ograničenom, a pola neograničenom ES-u:

$$IMCC = 0,5(5,87) + (1 - 0,5)(4,10) = 4,98 \% \quad (23)$$

Agregatni zahtjev za regulatorni kapital po pojedinom trgovinskom odjelu (C_A) izračunava se kao maksimum najnovijeg opažanja i ponderiranog prosjeka zadnjih 60 dana koji je skaliran za multiplikator (mc) u iznosu od 1,5.

$$C_A = \max\{IMCC_{t-1} + SES_{t-1}; m_c * IMCC_{avg} + SES_{avg}\} \quad (24)$$

SES – agregatni regulatorni kapitalni zahtjev za rizike koji se ne mogu modelirati, u ovom bi primjeru iznosio 0,3 %. Kapitalni zahtjev prema Baselu IV jednak je:

$$C_A = m_c * IMCC_{avg} + SES_{avg} = 1,5 \times 4,98 + 0,3 = 7,77 \% \quad (25)$$

Usporedni rezultati potrebnih kapitalnih zahtjeva na temelju Basela II, III i IV, tj. na temelju metodologija izračuna rizika - VaR, SVaR-a i ES predstavljeni su u Tablici 5.

Tablica 5. Usporedni prikaz potrebnih kapitalnih rezervi na temelju Basela II, III i IV

Regulativa	Metodologija	Iznos
Basel II	VaR 99 %	3,48 %
Basel III	SVaR+VaR 99 %	8,70 %
Basel IV	ES 97,5 %	7,77 %

Izvor: autorov izračun

Iz dobivenih rezultata vidljiva je drastična razlika između kapitalnih zahtjeva dobivenih na temelju regulative Basel II u odnosu na ostala dva pristupa, s

time da je kapitalni zahtjev kod Basela II više nego dvostruko manji od Basela III i IV. Budući da se za isti portfelj procjene razlikuju od 3,48 % prema Baselu II pa sve do 8,70 % po Baselu III jasno je zašto financijska industrija često negoduje na promjenu regulative s obzirom na to da izmjene Basela III znatno poskupljuju poslovanje banaka. Nakon sada već četvrtog kruga većih revizija zakonodavnog okvira regulator bi treba provesti dugotrajnije i sveobuhvatno testiranje uspješnosti predloženih modela te na temelju dobivenih rezultata pronaći izbalansirano rješenje koje će pokušati pomiriti sigurnost i profitabilnost poslovanja. U pogledu izbora metrike, tj. metodologije izračuna dublje razumijevanje funkcioniranja VaR-a i ES-a jasno pokazuje da dilema ne bi trebala postojati u smislu VaR-a ili ES-a već je očito da treba ići u smjeru VaR-a i ES-a kao podloge za izračun kapitalnih rezervi.

4. ZAKLJUČAK

Baselski odbor postavio je sustav međunarodnih standarda za regulaciju banaka, najviše putem ključnih publikacija koje se odnose na adekvatnost bankovnog kapitala, koje se u praksi nazivaju Basel I, Basel II, Basel III te najnovije Basel IV. U Europskoj uniji Baselski standardi implementirani su putem Smjernice o kapitalnim zahtjevima IV (CRDIV) i Uredbe o kapitalnim zahtjevima (CRR), a u Hrvatskoj su pretočeni u Zakon o kreditnim institucijama. Baselski odbor završio je svoje reforme u sklopu regulatornog paketa mjera Basel III 2017. godine. Jedan od ključnih ciljeva izmjena Basel III bio je smanjenje pretjerane varijabilnosti rizikom ponderirane imovine. Tijekom globalne financijske krize regulatori su izgubili povjerenje u bankovne interne modele te posljedično i stope adekvatnosti kapitala. Za vrijeme čekanja na konačan rok za implementaciju Basela III, Baselski odbor nastavio je prilagođavanje njegovih odredbi. Zaključne odredbe Basela III, a koje su donesene u razdoblju od 2016. do 2019. godine kolokvijalno se nazivaju „Baselom IV“. Basel IV započeo je s primjenom 1. siječnja 2023. godine. Vezano za mjerenje i upravljanje tržišnim rizikom u trgovinskoj knjizi banke Basel IV propisuje detaljan postupak odobravanja modela kako bi osigurao da se interni modeli koriste samo tamo gdje regulator ima potpuno povjerenje u njihovu valjanost. Ovaj pristup također je koncipiran s ciljem boljeg obuhvata kreditnih rizika povezanih s knjigom trgovanja, rizika od ekstremnih događaja te rizika nelikvidnosti. Zaključna faza Basela III, tj. Basel IV napušta koncept izračuna rizičnosti imovine temeljen na VaR-u te se sada oslanja na set indikatora čiju osnovicu čini očekivani manjak

u repu (*Expected shortfall* - ES). ES metodologija ima dvije ključne karakteristike koje rješavaju osnovne i dobro poznate nedostatke *Value at Risk* (VaR) metodologije, a to je da obuhvaća ekstremne rizike u repu distribucije koje VaR ne uzima u obzir te da u sklopu mjerenja rizika pomoću ES-a Basel propisuje različite horizonte likvidnosti za različite čimbenike rizika, uzimajući u obzir vrijeme potrebno za likvidaciju trgovinske pozicije bez značajnog utjecaja na tržišne cijene u kriznim uvjetima. ES je vrlo korisna i intuitivna mjera rizika koja se primarno fokusira na ekstremne događaje, tj. događaje u repu distribucije. Međutim, poput ostalih mjera rizika, ES ima svoja ograničenja koja treba uzeti u obzir. Ključni izazov u korištenju ES-a leži u potrebi procjene distribucije portfelja u repu, što može biti izazovno, posebno kada se radi o složenim ili nelikvidnim instrumentima s ograničenim povijesnim podacima.

Rezultati naše analize pokazuju signifikantne razlike između kapitalnih zahtjeva dobivenih na temelju regulative Basel II u odnosu na Basel III i IV, s time da su kapitalni zahtjevi kod Basela III i IV više nego dvostruko viši nego kod Basela II. Na temelju dobivenih rezultata može se zaključiti da u ovom analiziranom primjeru izgleda kao da se u Baselu IV ipak uvažio dio kritika industrije te je kapitalni zahtjev korigiran na niže u odnosu na prethodnu verziju, ali je ipak i dalje znatno viši od onog zahtijevanog prema Baselu II. Dio ovog povećanja zasigurno treba pripisati promjenama metodologije izračuna, koja sada počiva na ES metrici umjesto na VaR metrici te se time automatski najekstremniji gubitci na tržištu više ne mogu sakriti u samom repu distribucije povrata. U ovom radu prikazali smo samo grubu i jednostavnu procjenu kapitalnih zahtjeva na temelju triju verzija Baselske regulative, ali koje ipak pokazuju indikativne rezultate. U budućem istraživanju trebalo bi se usredotočiti ne samo na međusobnu usporedbu različitih metodologija već i na njihovu primjenjivost u stvarnim okolnostima, tj. na analizu koliko dobiveni rezultati odgovaraju stvarnim događanjima u kriznim situacijama te koliko su i najnovije regulative ispravno kalibrirane onome što se događa na financijskim tržištima tijekom kriza.

REFERENCE

1. Artzner P., Delbaen F., Eber J.M., Heath D. (1999) Coherent measures of risk, *Mathematical Finance* 9, p. 203-228
2. Basel Committee on Banking Supervision (BCBS) (1983) *Principles for the Supervision of Banks' Foreign Establishments*

3. Basel Committee on Banking Supervision (BCBS) (1988) *International Convergence of Capital Measurement and Capital Standards*
4. Basel Committee on Banking Supervision (BCBS) (1990) *Exchanges of Information Between Banking and Securities Supervisors*
5. Basel Committee on Banking Supervision (BCBS) (1991) *Amendment of the Basel capital accord in respect of the inclusion of general provisions/general loan-loss reserves in capital*
6. Basel Committee on Banking Supervision (BCBS) (1995) *Basel Capital Accord: treatment of potential exposure for off-balance-sheet items*
7. Basel Committee on Banking Supervision (BCBS) (1996) *Amendment to the capital accord to incorporate market risks*
8. Basel Committee on Banking Supervision (BCBS) (2005) *Amendments to the Capital Accord to incorporate market risks*
9. Basel Committee on Banking Supervision (BCBS) (2007) *Principles for home-host supervisory cooperation and allocation mechanisms in the context of Advanced Measurement Approaches (AMA)*
10. Basel Committee on Banking Supervision (BCBS) (2008) *Principles for Sound Liquidity Risk Management and Supervision*
11. Basel Committee on Banking Supervision (BCBS) (2009) *Revisions to the Basel II market risk framework*
12. Basel Committee on Banking Supervision (BCBS) (2010a) *Basel III: International framework for liquidity risk measurement, standards and monitoring*
13. Basel Committee on Banking Supervision (BCBS) (2010b) *Basel III: A global regulatory framework for more resilient banks and banking systems*
14. Basel Committee on Banking Supervision (BCBS) (2016) *Minimum capital requirements for market risk*
15. Basel Committee on Banking Supervision (BCBS) (2017) *Basel III: Finalising post-crisis reforms*
16. Basel Committee on Banking Supervision (BCBS) (2019) *Minimum capital requirements for market risk*
17. Kritzman M., Rich D. (2002) The Mismeasurement of Risk. *Financial Analysts Journal*, Vol. 58., No. 3., p. 91-99.
18. Zakon o kreditnim institucijama (NN / 159/13, 19/15, 102/15, 15/18, 70/19, 47/20, 146/20, 151/22).
19. Žiković S. (2008a) Quantifying Extreme Risks in Stock Markets: A Study of Former Yugoslavia States. *Zbornik radova Ekonomskog fakulteta u Rijeci, Časopis za Ekonomsku teoriju i praksu*, Vol.26. No.1., Ekonomski fakultet Rijeka, p. 41-68.
20. Žiković S. (2008b) Measuring Market Risk in CEE Countries, poglavlje u knjizi: *Accounting and Finance in Transition*, Vol. 5., urednik: Šević Ž., Greenwich University Press, London, Great Britain, ISBN: 1-86166-252-1, p. 77-102.

21. Žiković S. (2008c) Calculating VaR in EU Candidate States, *South East European Journal of Economics and Business (SEE Journal)*, Vol. 3. No. 1. School of Economics and Business, University of Sarajevo, p. 23-33.
22. Žiković S., Pečarić M. (2010b) Interaction of Value at Risk and Expected Shortfall: Application to Zagreb Stock Exchange, *Proceedings of 5th International Conference, An Enterprise Odyssey: From Crisis to Prosperity – Challenges for Government and Business*, University of Zagreb, Faculty of Economics and Business, Opatija, 26-29.05.2010. p. 760-772.
23. Žiković S., Pečarić M. (2010a) Modelling Extreme Events: Application to Zagreb Stock Exchange. *Ekonomski pregled*, Vol. 61, No. 1-2., p. 19-37.
24. Žiković S. (2010) *Market Risk In Transition Countries - Value At Risk Approach*, Ekonomski fakultet Sveučilište u Rijeci
25. Žiković S., Vlahinić-Dizdarević N. (2011) Similarities between Expected Shortfall and Value at Risk: Application to Energy Markets, *International journal of management cases (1741-6264)* 13(3), p. 386-399.
26. Žiković S., Tomas Žiković I. (2016) Two Sides of the Same Coin, Risk Measures in the Energy Markets, *Journal of Energy Markets*, 9(2), p.51-68.
27. Žiković S. (2017) Measuring Financial Risk in Energy Markets in *Applied Quantitative Finance 3rd edition*, edited by Chen, C., Härdle W.K. and Overbeck, L., Springer, Berlin, Heidelberg, p. 295-308.

INFLUENCE OF BASEL IV ON CAPITAL REQUIREMENTS FOR MARKET RISKS

Bojan Tomić, PhD

Effectus University, School for Finance and Business Law

e-mail: bojan.tomic2@gmail.com

Full Professor Saša Žiković, PhD

University of Rijeka, Faculty of Economics and Business

e-mail: sasa.zikovic@efri.uniri.hr

Lorena Jovanović, MEcon

University of Rijeka, Faculty of Economics and Business

e-mail: lorena.jovanovic@efri.uniri.hr

ABSTRACT

Basel IV is the industry name for the new global banking regulatory reform, scheduled to begin implementation in 2023. Basel IV builds on earlier reforms of Basel I, II, and III. In this fourth package of reforms, market risks and their calculation methodologies are again in focus. The main innovation in measuring market risks is the introduction of a new type of internal model for extreme risks and market liquidity risk called Expected Shortfall (ES). ES is a measure that focuses on risks occurring under extreme market conditions. While Value at Risk (VaR) focuses on the maximum potential loss at a certain confidence level (e.g., 99%), thereby ignoring the extremes beyond that threshold, ES measures the average loss in the extreme tail, thus representing a more robust and conservative measure of risk. This paper analyses the quantitative impact of the regulatory shift from the VaR methodology to the ES methodology in calculating capital reserves. The results show significant differences between the capital requirements based on Basel II regulations compared to Basel III and IV, with capital requirements under Basel III and IV being more than twice as high as those under Basel II.

Key words: Basel IV, capital requirements, market risk, VaR, ES

JEL classification: C22, C54, G21, G32

ESG RIZICI U BANKOVNOM SEKTORU: BIBLIOMETRIJSKA ANALIZA LITERATURE

izv. prof. dr. sc. Ana Ivanišević Hernaus

Sveučilište u Zagrebu Ekonomski fakultet

e-mail: aivanisev@net.efzg.hr

izv. prof. dr. sc. Branka Tuškan Sjauš

Sveučilište u Zagrebu Ekonomski fakultet

e-mail: btuskan@net.efzg.hr

SAŽETAK

Razvoj regulatornog okvira i povezan snažan rast donedavno skromnijeg interesa za održivim poslovanjem potaknuo je uključivanje okolišnih, socijalnih i upravljačkih (ESG) čimbenika u poslovanje financijskih i nefinancijskih subjekata. Održivo poslovanje ukazalo je i na nužnost praćenja izloženosti i upravljanja ESG rizicima, koji su u fokusu ovog rada, s naglaskom na klimatski rizik. Svrha rada jest ukazati na novija kretanja, kako u regulatornom okviru zemalja EU-a tako i u razvoju povezanog znanstvenoistraživačkog područja. Rad donosi sistematiziran pregled dosadašnjih regulatornih postignuća, s posebnim osvrtom na bankovni sektor jer je analizom sadržaja objava supervizora uočeno nedovoljno razumijevanje problematike ESG rizika od strane tržišnih sudionika i njihove integracije u poslovanje. Pregled razvoja i strukture znanstvenoistraživačkog područja omogućen je korištenjem bibliometrijske analize, čiji su rezultati potvrdili interdisciplinarnu prirodu područja, pružili uvid u značajne radove, najviše citirane autore i izvore publikacija relevantne za objavu istraživanja, te omogućili prepoznavanje ključnih tema i smjerova razvoja ovog područja.

Ključne riječi: ESG rizici, klimatski rizik, regulacija, banke, bibliometrijska analiza

JEL klasifikacija: G15; G21; M14; O16

1. UVOD

Kao rezultat veće osviještenosti o utjecaju poslovanja na društvo i prirodni okoliš, ali i obratno, u posljednjih nekoliko godina značajno je povećan interes država, regulatornih i nadzornih tijela, financijskih i nefinancijskih subjekata, znanstvene i stručne zajednice, potrošača i šire javnosti za okolišna, socijalna/društvena i upravljačka (engl. *Environmental, Social, Governance* – ESG) pitanja. Pritom se najveći naglasak stavlja na okolišna pitanja, među kojima prvenstveno na klimatske promjene.

Iako je utjecaj klimatskog rizika proučavan u brojnim gospodarskim sektorima, još se uvijek, u tom smislu, nedovoljno pozornosti posvećuje financijskom sektoru, a posebno bankovnom kao njegovu najvažnijem segmentu. Na to su još unatrag deset godina ukazivali i drugi autori (npr. Georgopoulou *et al.*, 2015). Desetljeće poslije vidljivi su pomaci, posebno u regulatornom smislu, dok u praksi još uvijek postoje nedoumice oko razumijevanja terminologije i obuhvata održivog poslovanja te izloženosti ESG rizicima, na što ukazuje i sadržaj objava supervizora o integraciji ESG kriterija u poslovanje.

Znanstvena istraživanja u području održivog poslovanja banaka intenzivirana su u posljednjih nekoliko godina (Nătescu i Cristea, 2020; Azmi *et al.*, 2021; Kalfaoglou, 2021; Galletta *et al.*, 2023 i dr.), pri čemu je primjetan rast interesa za klimatski rizik (npr. Nieto, 2019; Breitenstein *et al.*, 2021; Javadi i Al Masum, 2021). Međutim, još uvijek postoji niz otvorenih pitanja, kao i potreba za znanstvenim doprinosom, ponajprije u dijelu integracije klimatskog rizika u sustave upravljanja rizicima. Nagli rast broja i disperziranosti sadržaja istraživanja u posljednjih nekoliko godina nameće potrebu za sistematičnim prikazom i znanstvenog segmenta u ovom području. Potrebno je prepoznati ključne teme te procijeniti smjer razvoja daljnjih istraživanja, što je u ovom radu postignuto primjenom bibliometrijske analize – analize citata, analize zajedničkih citata i analize istovremenog pojavljivanja ključnih riječi.

Rad donosi višestruki znanstveni doprinos. U teorijskom smislu, izložen je sistematičan pregled regulatornog okvira EU-a za održivo poslovanje, odnosno financiranje, prema područjima (nefinancijsko izvješćivanje, tržište kapitala, Taksonomija EU-a, prudencijalni okvir), zaključno s 2023. godinom. Osim iz regulatorne perspektive, u radu se u empirijskom dijelu ESG rizici u financijskom sektoru razmatraju metodom analize sadržaja objava supervizora. Dodatno, pružene su nove i korisne spoznaje o ovom znanstvenoistraživačkom području, koje još uvijek nije na dovoljno jasan i primjenjiv način odgovorilo na otvorena pitanja.

Rad se sastoji od pet dijelova. Nakon prvog, uvodnog dijela, u drugom dijelu rada izložen je pregled regulatornog obuhvata i integriranja ESG rizika u okvir sustava upravljanja rizicima financijskih institucija. U trećem dijelu slijedi pregled procedure bibliometrijskog istraživanja, a njegovi rezultati i rasprava izloženi su u četvrtom dijelu, nakon kojeg slijedi zaključak kao posljednji dio.

2. ESG RIZICI: REGULATORNI OBUHVAT I INTEGRIRANJE U SUSTAVE UPRAVLJANJA RIZICIMA FINANCIJSKIH INSTITUCIJA

2.1. ODRŽIVA ULAGANJA I RIZICI ODRŽIVOSTI


Prvotna održiva ulaganja podrazumijevala su uskraćivanje financiranja poslovanja (poduzeća, projekata i proizvoda) koja ne ispunjavaju etičke standarde. Neispunjavanje etičkih standarda uključuje nepovoljan okolišni i/ili društveni utjecaj (primjeri obuhvaćaju proizvodnju i preradu nafte, duhansku industriju, proizvodnju i trgovanje oružjem, proizvodnju alkohola, kockanje). Stoga je inicijalni naziv za održiva ulaganja bio etička ulaganja (engl. *Ethical Investment*), a s vremenom je naglasak stavljen na društveno odgovorno poslovanje (engl. *Corporate Social Responsibility* – CSR) pa se s time pojavio i naziv društveno odgovornih ulaganja (engl. *Socially Responsible Investment*). Održiva ulaganja (engl. *Sustainable Investment*, *ESG Investment*) danas obuhvaćaju i ulaganja koja usmjeravaju sredstva u poslovanje koje aktivno pridonosi društvenoj pravednosti i jednakosti, zaštiti prirodnog okoliša, i/ili uporabi obnovljivih izvora energije te uvažava pozitivne upravljačke čimbenike, s nefinancijskim utjecajem koji nije strogo planiran, već je također kolateralan i doprinosi ostvarenju ciljeva održivosti. Konačno, održiva ulaganja uključuju i ona koja rezultiraju namjernim i planiranim pozitivnim društvenim, upravljačkim i/ili okolišnim učincima (engl. *Impact Investment*) (Caplan *et al.*, 2013; Ivanišević Hernaus, 2016; Tuškan Sjauš, 2022).

Prema Uredbi (EU) 2019/2088 o objavama povezanim s održivosti u sektoru financijskih usluga (engl. *Sustainable Finance Disclosure Regulation* – SFDR), usklađeno definiranje „održivih ulaganja” podrazumijeva da poduzeća u koju su usmjerena održiva ulaganja imaju dobre upravljačke prakse te da „ne čine bitnu štetu” ni okolišnom ni socijalnom cilju. Čimbenici održivosti obuhvaćaju okolišna i socijalna pitanja te pitanja u vezi sa zaposlenicima, poštovanjem ljudskih prava, borbom protiv korupcije itd. Pritom se očekuje i mogućnost mjerenja takvog doprinosa, odnosno odgovarajućeg uključivanja i vrednovanja

rizika održivosti kao okolišnog, socijalnog ili upravljačkog događaja ili uvjeta koji bi, ako do njega dođe, mogao uzrokovati stvaran ili potencijalno negativan bitan učinak na vrijednost ulaganja (Službeni list EU-a, 2019), odnosno uzrokovati lošu reputaciju i/ili financijsku štetu poduzeću.

Pojava i rast izloženosti *rizicima održivosti* u poslovanju ukazuju na nužnost njihova kvalitetnog obuhvata regulacijom, uvažavajući njihove posebnosti te značajnu međusobnu povezanost u usporedbi s tradicionalnim rizicima, a čiju pojavu mogu potaknuti. Pritom se *rizik klimatskih promjena* ističe kao rizik s najvećim potencijalom za destabilizaciju globalnog financijskog sustava, pa se ova dva termina često izjednačavaju, a dijelom se i preklapaju s ESG rizicima (okolišni – utjecaj poslovanja na okoliš i klimatske promjene, socijalni – utjecaj poslovanja na društvo, i upravljački – utjecaj poslovanja na upravljačke aspekte). Dodatno, takvi rizici uzrokuju i rast izloženosti rizicima povezanim s održivošću koji iz njih proizlaze (tranzicijski rizik, fizički rizik, reputacijski rizik, regulatorni rizik i rizik izvješćivanja o održivosti, rizik ponašanja i sl.). U usporedbi s karakteristikama tradicionalnog obuhvata financijskih rizika (kreditni rizik, rizik likvidnosti, rizik solventnosti, tržišni rizik, kamatni rizik, valutni rizik itd.) i nefinancijskih rizika (operativni rizik, rizik tehnologije, regulatorni rizik, pravni rizik, reputacijski rizik itd.), rizici održivosti imaju dugoročniji karakter pojavnosti, obilježje nelinearnog širenja te mogućnost istovremene aktivacije različitih kategorija financijskih rizika (Prikaz 1.).

Prikaz 1. Povezanost rizika održivosti, rizika povezanih s održivošću i financijskih rizika



Izvor: izrada autora

Na temelju izloženog pojmovnog određenja i obuhvata rizika održivosti, riječ je o široj skupini rizika, kod koje je posebno naglašen utjecaj okolišnog čimbenika, prije svega, klimatskih promjena (terminološki obuhvat rizika održivosti u stranoj literaturi: engl. *sustainability risks*, *climate risks*, *climate-related risks*, *ESG risks* – *environmental/social/governance risks*) u okviru okolišnog čimbenika. Okolišni rizik (engl. *environmental risk*) podrazumijeva rizik gubitaka zbog negativnog financijskog utjecaja okolišnih čimbenika. To obuhvaća čimbenike vezane uz klimatske promjene, prilagodbu klimatskim promjenama, održivu uporabu i zaštitu voda, tranziciju na kružno gospodarstvo, upravljanje onečišćenjem i zaštitom te obnovom bioraznolikosti. Skupina okolišnih rizika obuhvaća dvije vrste rizika. Pritom, fizički rizik (engl. *physical risk*) predstavlja rizik gubitaka uslijed negativnog financijskog učinka na poslovanje i rezultata poslovanja zbog utjecaja fizičkih učinaka okolišnih čimbenika na druge ili na vlastita ulaganja, npr. akutni ili kronični ekstremni vremenski događaji po učestalosti i intenzitetu (poplave, šumski požari, uragani i sl.) i postupne promjene klime. Tranzicijski rizik (engl. *transition risk*) jest rizik od gubitaka zbog nepovoljnog financijskog utjecaja na druge ili na vlastita ulaganja (porast troškova sirovina, troškova novih tehnologija, troškova poreza i različitih penalizacija neuvažavanja čimbenika održivosti i sl.), a koji proizlazi iz prelaska dotadašnjeg poslovanja na održivo. Aktivacija fizičkog i tranzicijskog rizika utječe na poslovanje poduzeća te, posljedično, i na cijelo gospodarstvo i financijski sustav, izravno preko npr. niže profitabilnosti ili smanjenja vrijednosti imovine, ili neizravno putem npr. makrofinancijskih promjena. U srednjem i dugom roku, navedeni rizici imaju utjecaj i na održivost i stabilnost poslovanja financijskih institucija, posebice onih čije je poslovanje vezano uz djelatnosti osjetljive na okolišne rizike, kao, primjerice, bankovnog sektora. Reputacijski rizik (engl. *reputational risk*) povezan je s gubicima zbog štetnih utjecaja pojave problema iz područja održivosti na ime i ugled. Regulatorni rizik i rizik izvješćivanja (engl. *regulatory and reporting risk*) predstavlja rizik gubitaka zbog neusklađenosti poslovanja i izvješćivanja prema regulaciji o transparentnosti izvješćivanja o održivosti ili lažnog oglašavanja održivosti (područje *impact washing*). Rizik ponašanja (engl. *conduct risk*) vezan uz (ne)uvažavanje čimbenika održivosti uzrokuje štetu potrošačima ili može uzrokovati i tržišnu nestabilnost.

U praksi financijskih institucija primjetne su poteškoće u oblikovanju i razvoju strategija i politika za uključivanje rizika održivosti u poslovne procese. Pritom je mogućnost mjerenja učinaka, kao i usklađenost kriterija u području održivih ulaganja i poslovanja jedna od važnijih odrednica transparentnog i kvalitetnog nefinancijskog izvješćivanja – izvješćivanja o održivosti, koje je u novije

vrijeme dobilo i regulatornu podlogu. To je temeljno Uredba (EU) 2019/2088 o objavama povezanim s održivosti u sektoru financijskih usluga (SFDR) (Službeni list EU-a, 2019), Uredba (EU) 2020/852 o uspostavi okvira za olakšavanje održivih ulaganja ili Uredba o EU taksonomiji (Službeni list EU-a, 2020) i Direktiva (EU) 2022/2464 o korporativnom izvještavanju o održivosti poslovanja (CSRD) (Službeni list EU-a, 2022). Odrednice strategije i politike održivosti na ovaj način značajno utječu na prilagodbu tradicionalne strategije poslovanja financijskih institucija u mnogim segmentima.

2.2. REGULATORNI OKVIR EU-A U PODRUČJU ODRŽIVOG POSLOVANJA U FINACIJSKOM SEKTORU

S razvojem regulatornog okvira održivog poslovanja, EU prednjači na globalnoj razini u poticanju tranzicije na resursno učinkovitije i održivije gospodarstvo. Regulacija takvog poslovanja, koja donedavno nije postojala, u posljednjih se nekoliko godina na razini EU-a razvija vrlo intenzivno i praćena je eksponencijalnim rastom općeg interesa za održivim poslovanjem. U Tablici 1. prikazan je obuhvat važnijih regulatornih dokumenata. Iz njega je vidljivo da je nakon 2019. godine nastala glavnina konkretnije, transparentnije i sveobuhvatnije regulacije, koja je omogućila kvalitetnije vrednovanje i usporedivost čimbenika i učinaka u području održivosti, važnih za donošenje financijskih, odnosno poslovnih odluka. Unatoč dosadašnjim regulatornim postignućima, otvoren je prostor za razvoj regulacije te se u narednim godinama očekuje njezin daljnji snažan razvoj s obzirom na tržišna očekivanja mjerljive učinkovitosti i transparentnosti objava o održivosti, a u cilju omogućavanja kvalitetnije analize, procjene te usporedbe i nefinancijskih učinaka potencijalnih ulaganja.

Tablica 1. Razvoj regulatornog okvira održivog poslovanja u EU-u (distribucija po područjima uz prikaz obuhvata uređenja)

<i>Regulatorni okvir</i>	<i>Područje uređenja</i>
Taksonomija	
Uredba (EU) 2020/852 o uspostavi okvira za olakšavanje održivih ulaganja ili Uredba o EU taksonomiji (engl. <i>EU Taxonomy Regulation</i> – TR; primjenjuje se od siječnja 2022. godine) Novi skup pravila i čimbenika kojima se nadopunjuje primjena taksonomije EU-a: Delegirana Uredba (EU) 2021/2139 (engl. <i>Climate Delegated Act</i>) Delegirana Uredba (EU) 2021/2178 (engl. <i>Disclosure Delegated Act</i>) Delegirana Uredba (EU) 2022/1214 (engl. <i>Complementary Climate Delegated Act</i>;)) Delegirana Uredba (EU) 2020/852 (engl. <i>Environmental Delegated Act</i>)	Propisivanje kriterija prema kojima se neka ekonomska aktivnost kvalificira kao ona koja pridonosi održivosti (naglasak na okolišne ciljeve) rezultiralo je donošenjem standarda, odnosno preporuka za izdavanje inovativnih financijskih instrumenata koji uvažavaju čimbenike održivosti (standard EU-a za zelene obveznice).* Objave uključuju kapital, rashode i promet održivog poslovanja sukladno taksonomiji, za sudionike na fin. tržištu – poslovne subjekte na koje se odnosi Direktiva (EU) 2022/2464 o korporativnom izvješćivanju o održivosti (fokus na kompanije i financijski sektor, no ohrabruje i privatni kapital u financiranju projekata i tehnologija koji pridonose tranziciji k održivosti). Usmjerenost na smanjenje i prilagodbu klimatskim promjenama, održivu uporabu i očuvanje voda mora, prijelaz na kružno gospodarstvo, sprečavanje i kontrolu zagađenja, očuvanje bioraznolikosti i ekosustava. Usmjerenost na prilagodbu i poboljšanje kvalitete objava o održivosti (fokus na okolišne čimbenike, uz uvažavanje i društvenih te upravljačkih čimbenika); prema posebnim uvjetima, fosilni plin i nuklearna energija postaju prihvatljivi u kontekstu održivosti.
Nefinancijsko izvještavanje i druge objave	
Uredba (EU) 2019/2089 u pogledu referentnih vrijednosti za klimatske promjene (engl. <i>Climate Benchmark Regulation</i> – CBR; primjena od travnja 2020. godine)	Indeksi koji predstavljaju referentne vrijednosti uvažavajući čimbenike održivosti i pravila za referentne klimatske indekse.
Uredba (EU) 2019/2088 o objavama povezanim s održivosti u sektoru financijskih usluga (engl. <i>Sustainable Finance Disclosure Regulation</i> – SFDR, djelomična primjena od 2021.; puna od 2023. godine)	Integracija rizika održivosti te transparentnost objava o rizicima održivosti i negativnim učincima (uključivanje u investicijske analize). Obveznici primjene su sudionici na financijskom tržištu (ponuđači investicijskih proizvoda i financijski savjetnici).

Direktiva (EU) 2022/2464 o korporativnom izvještavanju o održivosti poslovanja (engl. <i>Corporate Sustainability Reporting Directive</i> – CSRD; početak primjene od 2024. godine; sljednica Direktive (EU) 2014/95/EU – <i>Non-financial Reporting Directive</i> – NFRD) Nadopuna Direktivi CSRD: Delegirani akt kojim se nadopunjuje Direktiva 2013/34/EU o godišnjim fin. izvještajima, konsolidiranim fin. izvještajima i povezanim izvješćima za određene vrste poduzeća, u dijelu standarda izvještavanja o održivosti (engl. <i>European Sustainability Reporting Standards</i>; prijedlog u lipnju 2023. godine)	Potpunije i transparentnije izvještavanje o održivosti (koliko je prihoda ostvareno iz poslovanja usklađenog s taksonomijom); u 2025. za 2024. godinu obvezna objava za financijska i nefinancijska poduzeća od javnog interesa s preko 500 zaposlenih; obveza prve objave 2026. za 2025. godinu za društva koja zadovoljavaju 2 od 3 kriterija, i posluju u Europskoj uniji: neto imovina veća od 20 mil. EUR, neto prihod veći od 40 mil. EUR, više od 250 zaposlenih; društva čije vrijednosnice kotiraju na jednoj od europskih burzi (isključujući mikropoduzeća); obveza objave prvih izvješća 2027. za 2026. godinu i za sva mala i srednja poduzeća s izlistanim vrijednosnicama. Izvješća na temelju formalnih standarda izvještavanja o održivosti koja podliježu vanjskoj reviziji (<i>Global Reporting Initiative</i> – <i>GRI Standards</i>).
Prudencijalni okvir	
Akcijski plan Europskog nadzornog tijela za bankarstvo (EBA, 2019), Smjernice o upravljanju i superviziji ESG rizika u bankama (EBA, 2021), Smjernice o implementaciji tehničkih standarda za objave o ESG rizicima (EBA, 2022a); Uloga ESG rizika u bonitetnom zakonodavstvu (EBA, 2022c), Smjernice ESB-a za rizike povezane s klimatskim promjenama i okolišne rizike (ESB, 2020), Smjernice ESB-a za testiranje klimatskog rizika (ESB, 2022a; ESB, 2022b)	Integriranje rizika održivosti u širi okvir bonitetne regulacije (područja: minimalni kapitalni zahtjevi, supervizija, tržišna disciplina). Uvođenje tehničkih standarda za integriranje ESG rizika u okvir regulatornog paketa CRR/CRD (Uredbe (EU) 575/2013 o bonitetnim zahtjevima za kreditne institucije i investicijska društva – engl. <i>Capital Requirements Regulation</i> – CRR I), odnosno Uredbe (EU) 2019/876 (CRR II od 2021. godine) i Direktive 2013/36/EU o pristupanju djelatnosti kreditnih institucija i bonitetnom nadzoru nad kred. institucijama i inv. društvima (engl. <i>Capital Requirements Directive</i> – CRD IV), tj. Direktive 2019/878/EU (CRD V od 2021. godine).
Tržište kapitala	
Druga direktiva (EU) 2017/828 o pravima dioničara (<i>Second Shareholder Rights Directive</i> – SRD II; na snazi od 2020. godine)	Usmjerenost na integraciju interesa ulagača za ispunjavanje kriterija održivosti i dugoročnu održivost ulaganja – važan čimbenik Unije tržišta kapitala.
Delegirana legislativa za integraciju održivosti (engl. <i>Delegated legislation integrating sustainability in UCITS</i>; <i>Delegated legislation integrating sustainability in AIFMs</i>; <i>Delegated legislation integrating sustainability in MiFID II</i>; <i>Delegated legislation integrating sustainability in IDD</i>)	Usmjerenost na upravljanje rizicima održivosti putem integracije održivosti u poslovanje: fondova UCITS, alternativnih investicijskih fondova, tržište financijskih instrumenata i distribuciju osiguranja.

Smjer razvoja regulacije u budućem razdoblju	
Prijedlog Uredbe o transparentnosti i integritetu ocjenjivanja ESG čimbenika (engl. <i>Proposal for a Regulation on the transparency and integrity of Environmental, Social and Governance (ESG) rating activities</i> ; prijedlog u lipnju 2023. godine)	Usmjerenost na poboljšanje kvalitete ocjenjivanja uvažavanja ESG čimbenika. Sastavnica je obnovljene strategije u vezi s održivim financiranjem (Europska komisija, 2021).
Prijedlog Direktive o dubinskoj analizi održivosti poslovanja (engl. <i>Corporate Sustainability Due Diligence Directive – CSDDD</i> ; prijedlog u lipnju 2023. godine)	Usmjerenost na dubinsku analizu pridržavanja standarda održivosti (poticanje održivog i odgovornog ponašanja kompanija) s uvažavanjem ne samo okolišnih već i društvenih i upravljačkih čimbenika (nadopuna regulatornom paketu SFDR-a i CSRD-a). Obveznici su: 1. sva poduzeća (d.o.o.) EU-a koja imaju više od 500 zaposlenih i neto promet veći od 150 mil. EUR, 2. ostala poduzeća (d.o.o.) EU-a u djelatnostima s visokim učinkom, koja ne ispunjavaju navedene uvjete, ali imaju više od 250 zaposlenih i neto promet veći od 40 mil. EUR (s odgodom primjene od dvije godine), i 3. neeuropska poduzeća s poslovanjem na području EU-a i prethodnom definiranim neto prihodima. Mala i srednja poduzeća ne podliježu regulaciji.
Integriranje rizika održivosti u okvir šire regulacije EU-a bonitetnog rizika – engl. <i>Prudential Legislative Texts</i>	Cilj je prilagodba uključivanja rizika održivosti u politike, procedure, strategije te sustave upravljanja i odlučivanja za sve tržišne sudionike.

* Preporuke za izdavanje inovativnih ESG financijskih proizvoda donesene nakon 2020. godine:

- Standard EU-a za zelene obveznice (engl. *EU Green Bond Standard – EUGBS*), propisuje minimalne zahtjeve za označavanje obveznica „zelenima“ (najmanje 85 % tako pribavljenih sredstava mora biti usmjereno u ekonomske aktivnosti propisane Uredbom (EU) 2020/852 o taksonomiji); dodjela ekoloških oznaka (engl. *EU EcoLabel*) proširena je i na financijsku uslužnu djelatnost.
- Načela za izdavanje društvenih obveznica ICMA-e (engl. *Social Bond Principles*), podloga i za izdavanje društveno uključivih obveznica (engl. *Social Inclusion Bonds*).
- Načela za izdavanje održivih obveznica ICMA-e (engl. *Sustainability Bond Principles*) i Načela za izdavanje s održivošću povezanih obveznica ICMA-e (engl. *Sustainability-Linked Bond Principles*).

Izvor: izrada autora prema službenim podacima i objavama Europske komisije (Službeni list Europske unije, 2013, 2014, 2017, 2019, 2020, 2022) te nadležnih regulatornih i nadzornih tijela (Europska središnja banka, 2020, 2022a, 2022b; Europsko nadzorno tijelo za bankarstvo, 2019, 2021, 2022a, 2022c)

Navedene direktive i uredbe temelj su regulacije u području održivog poslovanja i uključivanja rizika održivosti u politike i objave informacija. Njihov je cilj

transparentnost i usporedivost objava o održivom poslovanju u EU-u, zaštita investitora i europskih poslovnih subjekata koji su prema njima uskladili izvješćivanje, od nelojalne konkurencije koja dolazi izvan Europe, a što uključuje i tematiku manipulativnog nefinancijskog izvješćavanja (npr. *impact washing*, *greenwashing*, *social washing*, *pink washing*, *blue washing* i sl.).

Prikazan regulatorni okvir uvažava: a) Europski zeleni plan (engl. *European Green Deal 2019 – 2050*) kao najvažniju inicijativu u području održivosti, odnosno cilj da Europa do 2050. godine postane klimatski neutralan kontinent sukladno b) Pariškom sporazumu, odnosno konvenciji Ujedinjenih naroda o klimatskim promjenama (engl. *Paris Climate Agreement 2015*), c) UN Program održivog razvoja (engl. *United Nations' 2030 Agenda for Sustainable Development and the SDGs (2015)*), čijih je 17 ciljeva održivog razvoja bilo podloga za donošenje Europskog zelenog plana, d) Akcijski plan Europske komisije (engl. *EC Action Plan for Financing Sustainable Growth 2018 – 2050*) (Tuškan Sjauš *et al.*, 2023). Navedeni planovi predstavljaju strategije djelovanja u području održivosti, s trima ciljevima: usmjeravanje kapitala u održiva ulaganja (podloga za Uredbu o taksonomiji EU-a, standarde EU-a za održive financijske proizvode, razvoj referentnih vrijednosti održivosti te dodjelu ekološke oznake EU-a); upravljanje financijskim rizicima koji se pojavljuju zbog klimatskih promjena, okolišnih i društvenih degradacija (podloga za nadogradnju bonitetne regulative u smjeru integracije rizika održivosti i obveze provedbe stres-testova za klimatski rizik u okvir šire bonitetne regulacije); poticanje transparentnosti i dugoročnosti u planiranju financijskih i ekonomskih aktivnosti u ESG području (Ernst & Young, 2022).

Može se primijetiti kako je jedno od ključnih područja na koje su prikazana regulatorna rješenja usmjerena upravo područje upravljanja rizicima, s ciljem integriranja rizika održivosti u sustav upravljanja rizicima. Za očekivati je daljnje intenziviranje aktivnosti u tom kompleksnom području. Rizici održivosti kao nefinancijski rizici u budućnosti će biti jedne od važnijih odrednica ukupnog sustava upravljanja rizicima, zbog već uočenog i dokazanog utjecaja klimatskih promjena na pojavu najvažnijih kategorija financijskih rizika kojima su financijske institucije izložene, koji proizlaze iz specifičnosti njihova poslovnog modela.

2.3. FINANCIJSKE INSTITUCIJE I UPRAVLJANJE KLIMATSKIM RIZIKOM

Uredba SFDR temeljna je regulacija kojom se uređuje integriranje rizika održivosti u poslovanje, odnosno obveza izvješćivanja (objava) ulagateljima o odr-

živom poslovanju. Uredbom se željela postići ujednačenost i transparentnost objava o održivosti definiranjem okvira održivosti, štetnih učinaka, rizika održivosti, metrike, te obveznika primjene Uredbe i načina na koji uključuju rizike održivosti u ulagačke odluke. Nedostatak standardizacije nefinancijskog izvješćivanja može ugroziti tržišno natjecanje (Službeni list Europske unije, 2019; Gaganis *et al.*, 2023).

Prema Uredbi proizlazi da sudionici na financijskim tržištima i financijski savjetnici koji pružaju usluge investicijskog savjetovanja ili savjetovanja o osiguranju u vezi s investicijskim osigurateljnim proizvodima, u cilju djelovanja u najboljem interesu krajnjih ulagatelja, u procese odlučivanja o ulaganjima, organizaciju poslovanja, upravljanje rizikom i povezane upravljačke aspekte i savjetodavne procese, uključujući procese dužne pozornosti i uzimanja u obzir glavnih štetnih učinaka, trebaju pored relevantnih financijskih rizika uključiti i relevantne rizike održivosti, koji bi mogli imati bitan negativan učinak na financijski povrat ulaganja ili savjetovanje. Rizike održivosti trebaju kontinuirano ocjenjivati na temelju objavljenih politika o njihovu uključivanju, uz osiguranje transparentnog, standardiziranog objavljivanja o uključivanju. Nefinancijsko izvješćivanje može se obavljati ključnim pokazateljima adekvatnim za mjerenje odabranog cilja održivosti. Osim koristi na financijskom tržištu, opisani pristup poslovanju može povećati i otpornost gospodarstva i stabilnost financijskog sustava te, u konačnici, utjecati na omjer rizika i povrata financijskih proizvoda.

Premda klimatskim rizikom iz šireg okvira rizika održivosti, pored drugih ekonomskih sektora, pozornost sve više posvećuje i financijski sektor (financijske institucije utječu na klimatske promjene i okoliš vlastitim djelovanjem, te preko klijenata kojima su izložene), i dalje je primjetan nedovoljan angažman u integriranju tog rizika. Donošenje strategija za integriranje klimatskog rizika (npr. u kreditne analize pri odobravanju bankovnih kredita), te stvaranje okvira za provođenje stres-testova za klimatski rizik nedovoljno je razvijeno s obzirom na rokove obvezne primjene. Rezultati ESB-a (2022a) testiranja na stres za klimatski rizik na uzorku 104 značajne europske banke ukazali su na to da 60 % banaka još nije imalo razvijenu dovoljno kvalitetnu strategiju za integraciju klimatskog rizika i provedbu stres-testova sukladno objavljenoj metodologiji (ESB, 2021).

Europska nadzorna tijela *European Banking Authority* – EBA, *European Insurance and Occupational Pensions Authority* – EIOPA i *European Securities Market Authority* – ESMA zadužena su za poticanje transparentnosti objava

o uvažavanju održivosti u financijskom sektoru. EBA je, stoga, za banke donijela obvezujuće tehničke standarde, odnosno smjernice za objavu informacija o klimatskim rizicima i planovima za njihovim integriranjem (EBA, 2022a). Pritom su definirani pokazatelji održivosti poslovanja koje će banke morati objavljivati s ciljem informiranja o usklađenosti svog poslovanja s taksonomijom EU-a, odnosno kako doprinose smanjenju klimatskog rizika podržavajući zelenu tranziciju svojih klijenata, a uključuju omjer „zelene“ aktive (engl. *Green Asset Ratio* – GAR; ukazuje na udio „zelene“ kreditne izloženosti prema velikim korporacijama i sektoru stanovništva, uključujući „zelene“ stambene kredite i kredite za kupnju automobila) i omjer usklađenosti s taksonomijom EU-a (engl. *Banking Book Taxonomy Alignment Ratio* – BTAR; ukazuje na udio izloženosti prema malim i srednjim poduzećima čije je poslovanje usklađeno s taksonomijom). Velike korporacije obveznici su objava o održivosti, dok podatke o održivosti za mala i srednja poduzeća te sektor stanovništva banke trebaju prikupljati od klijenata (npr. certifikati o energetske učinkovitosti stambenih nekretnina pri kupnji stana na kredit, ali i automobila; koliko je temeljno poslovanje malih i srednjih poduzeća usklađeno s taksonomijom, a što ovisi o sektoru, geolokaciji i sl.). Istovremeno, banke su obvezne objavljivati i informacije o svojoj izloženosti prema 20 najvećih globalnih zagađivača (odobreni krediti i ulaganja u obveznice i dionice takvih korporacija). Cilj je nefinancijskim izvještavanjem utvrditi i obuhvatiti u kojoj mjeri i na koji način, izravno ili neizravno, poslovanje banaka podržava zagađenje (mjereno emisijom stakleničkih plinova); najveći ponder ima vlastita emisija, a drugi po značajnosti ponder ima korištenje električne energije iz neobnovljivih izvora, te se oba područja odnose na izravan doprinos banaka zagađenju i u tom je smislu izloženost banaka relativno niska, za razliku od značajnije više izloženosti preko treće kategorije (indirektnog doprinosa, najmanji ponder), koja obuhvaća financijsku podršku emisiji preko kredita i ulaganja u zagađivače. Na temelju informacija o održivosti ESG rizični razredi mogu obuhvatiti pet razina rizika: prihvatljivu (0 – 10 bodova), nisku (10 – 20 bodova), srednju (20 – 30 bodova), visoku (30 – 40 bodova) i vrlo visoku (> 40 bodova). Inkorporiranje rizika održivosti u supervizijski okvir društava koja obavljaju investicijske aktivnosti (kreditne institucije, investicijska društva) EBA prati putem analize poslovnih modela subjekata nadzora s aspekta održivosti (strategije poslovanja, financijski planovi i sl.), internog upravljanja i upravljanja rizicima s različitih aspekata, uvažavajući čimbenike održivosti (EBA, 2021; EBA, 2022b).

Važnost uvažavanja rizika održivosti proizlazi iz činjenice da čimbenici održivosti mogu značajno pridonijeti ukupnom rizičnom profilu financijske institu-

cije (rizik održivosti kao pokretač kreditnog rizika i sl.) te, u konačnici, činjenici da su rizici održivosti nepredvidivi ili teže predvidivi i zato predstavljaju poseban izazov upravljanja rizicima. Sustavna integracija financijski značajnih rizika održivosti i učinaka u području održivosti postaje neophodna u financijskom odlučivanju. Kako bi to bilo moguće, potrebno je istražiti i raspoloživu literaturu, odnosno dosadašnja istraživanja teme izloženosti i upravljanja ESG rizicima i posebnom klimatskom riziku u bankovnom sektoru.

3. PROCEDURA: PODACI I METODE ISTRAŽIVANJA

3.1. TEHNIKE BIBLIOMETRIJSKOG MAPIRANJA

U radu je provedena bibliometrijska analiza sekundarnih podataka. Takva analiza, koristeći se podacima o brojevima i autorima znanstvenih publikacija te o radovima i citatima u njima, pruža korisne spoznaje za znanstvenike koji vrednuju znanstvenu aktivnost (Rey-Martí *et al.*, 2016). Omogućava niz spoznaja, uključujući mjerenje znanstvene produktivnosti pojedinaca i istraživačkih timova, institucija i zemalja, utvrđivanje nacionalnih i međunarodnih mreža, kao i mapiranje razvoja novih (multidisciplinarnih) područja znanosti i tehnologije (OECD, 2019; Zupic i Čater, 2015). Metoda je korištena kvantitativno, obuhvaćajući bibliometrijsku analizu citata, analizu istovremenog pojavljivanja ključnih riječi i analizu zajedničkih citata kako bi se pristupilo raznim pitanjima u području ESG rizika u bankovnom sektoru, s fokusom na sve važnije rizike povezane s klimatskim promjenama.

3.2. TIJEK ISTRAŽIVANJA

Istraživanje se sastoji od četiriju koraka: (1) dizajna istraživanja, (2) prikupljanja podataka, (3) deskriptivne analize te (4) vizualizacije i interpretacije bibliometrijskih podataka.

Korak 1.: Dizajn istraživanja. Povećan praktičan, a u posljednjih nekoliko godina i regulatorni značaj ESG rizika u poslovanju financijskih institucija – banaka kao najvažnijih, te, s druge strane, nedostatak znanstvenih istraživanja tog potpodručja održivih financija bila je motivacija za istraživanje ove teme. Praksa se još uvijek razvija i traži „rješenja“ za brojne izazove ESG prirode i njihov utjecaj na poslovanje financijskih i nefinancijskih društava. U području je sve snažnije izražena potreba upravo za istraživanjima koja će unaprijediti,

potkrijepiti ili opovrgnuti tu praksu. Stoga se postavljaju pitanja o razvoju ovog znanstvenog područja s vremenom, o njegovoj strukturi i o značaju pojedinih tema. Odgovore na ta pitanja pruža bibliometrijska analiza. S obzirom na to da istraživačka pitanja zahtijevaju različite bibliometrijske metode, primijenjena je odgovarajuća metoda za svako specifično istraživačko pitanje. Konkretno, kako bi se utvrdilo tko su glavni autori i najviše citirani radovi, provedena je analiza citata radi prikaza osnovnih obilježja područja. Nadalje, analizom istovremenog pojavljivanja ključnih riječi utvrđeni su povezani pojmovi koji se najčešće istražuju. Konačno, analiza zajedničkih citata nudi odgovore o intelektualnoj strukturi područja, tj. koji su sekundarni radovi istovremeno korišteni kao reference u primarnim radovima na istraženu temu.

Iako već postoje bibliometrijski pregledi u području održivih financija u bankovnoj industriji (npr. Galletta *et al.*, 2022), kao i problematike ESG rizika općenito (npr. de Giuli *et al.*, 2023), koliko je autorima poznato, navedeni pristup u ovom potpodručju održivih financija do sada nije bio ponuđen znanstvenoj i stručnoj javnosti, odnosno nisu nađena istraživanja koja bi ovim pristupom cjelovito obrađivala literaturu o ESG rizicima u bankovnom sektoru, na kojoj je fokus. Stoga se pristup bibliometrijskom analizom nameće kao koristan i potreban, kao i njegovo obnavljanje zbog snažnog razvoja područja u posljednjih nekoliko godina, koji se očekuje i u budućem razdoblju.

Korak 2.: Prikupljanje podataka. Kako bi se provele navedene metode bibliometrijske analize, određen je uzorak, odnosno baza dokumenata/radova. Odbrana je baza podataka *Web of Science* (WoS) jer je riječ o najčešće korištenoj bazi podataka za bibliometrijske analize i koja pokriva 22.171 časopisa (preko 91 milijun zapisa), više od 143.000 knjiga i radove vezane uz više od 304.000 konferencija (Clarivate, 2024). Multidisciplinarni karakter korištene baze i bogatstvo referenci, između ostalog, čine je desetljećima prvim izborom (Garcia-Machado, 2018). Uzorak analiziranih radova obuhvaća radove o ESG rizicima u bankovnom poslovanju od pojave prvih radova na tu temu, te je analizirano razdoblje od 2006. do 2023. godine. Nije bilo ograničenja u pogledu izbora vrste radova. Kompilacija sekundarnih (bibliometrijskih) podataka iz baze *Web of Science* pokrenuta je odabirom kriterija pretraživanja. U želji za istraživanjem potpodručja financijskih istraživanja održivog poslovanja financijskih institucija (isključujući razmatranje širih tema održivog poslovanja), korištena su specifična četiri pojma za pretraživanje rizika koji se dijelom preklapaju te pojam određenja vrste financijske institucije, tj. *ESG risk OR sustainability risk OR climate risk OR climate-related risk AND bank* OR banking* (ESG rizik ILI

rizik održivosti ILI klimatski rizik ILI rizik povezan s klimatskim promjenama I banka ILI bankarstvo). Tim pojmovima pretražena je baza podataka prema kategoriji *Title*, koja uključuje naslov rada, sažetak, ključne riječi definirane od strane autora i dodatne ključne riječi definirane od strane baze *Web of Science*. Pretraživanje metapodataka rezultiralo je podudaranjem 81 dokumenta/rada. Svi su radovi i dodatno pregledani analizom sažetaka kako bi se iz daljnje analize isključili oni koji nisu povezani s temom. Isključeno je 9 radova, što je u konačnici rezultiralo sa 72 rada.

Korak 3.: Deskriptivna analiza. Za dobivanje početnog pogleda na skup podataka korišten je alat za analizu baze *Web of Science*. Deskriptivna analiza provedena je kako bi se odredila učestalost i postoci za nekoliko kategorijskih varijabli promatranih u istraživanju (kategorije baze *Web of Science*, godine izdanja, vrste radova, autori, institucije i zemlje kojima autori pripadaju i naslovi časopisa u kojima su radovi objavljeni).

Korak 4.: Vizualizacija i interpretacija bibliometrijskih podataka. Nakon deskriptivne analize, napravljena je bibliometrijska analiza. Za njezino provođenje odabran je VOSviewer kao široko prihvaćen softverski alat razvijen u svrhu izrade i vizualizacije bibliometrijskih mapa. Pomoću njega moguće je provesti razne oblike mapiranja područja istraživanja, kao i druge analize.

4. REZULTATI ISTRAŽIVANJA I RASPRAVA

4.1. DESKRIPTIVNA ANALIZA

Eksplorativna deskriptivna analiza pružila je uvid u ukupan broj radova u različitim domenama, prema autorima i izvorima publikacija, zemljopisnoj pokrivenosti istraživanja, kao i s obzirom na vremenski prikaz objavljivanja.

Predmetne kategorije. Početni korak odabira navedenih kriterija pretraživanja rezultirao je s 81 radom iz baze *Web of Science Core Collection*, kojima je bilo pokriveno 25 različitih predmetnih kategorija (primjenjuje se više kategorija po predmetu). U sljedećem koraku izabrana su niže navedena znanstvena područja, prema kojima je zastupljenost radova bila kako slijedi: *Znanosti o okolišu* (20), *Istraživanja o okolišu* (16), *Ekonomija* (18), *Poslovne financije* (18), *Poslovanje* (5), *Pravo* (5), *Javna administracija* (5), *Upravljanje* (3), *Politike agrarne ekonomike* (2), *Interdisciplinarne društvene znanosti* (1). Taj je korak formirao spomenutu konačnu bazu od 72 rada.

Tablica 2. Zastupljenost radova o ESG rizicima u bankovnom poslovanju prema znanstvenim područjima

Znanstveno područje	Broj radova
Znanosti o okolišu	20
Istraživanja o okolišu	16
Ekonomija	18
Poslovne financije	18
Poslovanje	5
Pravo	5
Javna administracija	5
Upravljanje	3
Politike agrarne ekonomike	2
Interdisciplinarne društvene znanosti	1

Izvor: izrada autora prema bazi Web of Science

Glavni izvori radova. Istraživanje teme ESG rizika u bankovnom poslovanju pojavilo se u različitim izvorima radova. Više od 90 % analiziranih radova objavljeno je u obliku članka. Druge vrste dokumenata indeksiranih u bazi *Web of Science* (rani pristup, pregledni rad, poglavlje knjige te, u najmanjoj mjeri, urednički materijal i konferencijski referat) bile su značajno manje zastupljene. Istraživanja su objavljena u 52 različita izvora, pri čemu su časopisi *Sustainability* (8,1 %), *Climate Policy* (6,8 %), *Climate Risk Management* (5,4 %), *Economic Change and Restructuring* (4,1 %) i *International Review of Financial Analysis* (4,1 %) bili najčešće ciljani izvori objavljivanja.


Autori s najvećim doprinosom. Utvrđeni su autori s najvećim brojem radova. Među 207 autora koji su objavljivali radove na teme iz promatranog područja, Shouwei Li sa sveučilišta *Southeast University*, Nanjing (Kina), jedini je imao tri publikacije, a slijede ga Savino Di Lernia sa sveučilišta *Sapienza Università di Roma* (Italija), Nawazish Mirza s učilišta *Excelia Business School*, La Rochelle (Francuska), María J. Nieto iz *Bank of Spain* (Španjolska), Paweł Niedziółka s učilišta *Warsaw School of Economics* (Poljska), Christina P. Skinner s učilišta *Wharton School* (SAD), Mohammed Umar sa sveučilišta *Hamad Bin Khalifa University* (Katar) i Xin Wu sa sveučilišta *Zhejiang University of Finance & Economics* (Kina), koji imaju po dvije publikacije.

Kartografija istraživanja. Populacija istraživanja sastoji se od autora koji dolaze iz 38 zemalja, s dominacijom znanstvenika zaposlenih u Kini (24,3 %) i SAD-u (23,0 %), koje slijede autori zaposleni u Engleskoj (14,9 %) i Francuskoj (12,2

%). Među zemljama s udjelom ispod 10 % dobro su zastupljeni i znanstvenici iz Italije (9,5 %), Australije (8,1 %), Kanade (8,1 %) i Njemačke (8,1 %), Španjolske (6,8 %) i Poljske (5,4 %), dok su istraživači iz drugih zemalja zastupljeni s manje od 5 %. Prema svemu navedenom, postoji respektabilna geografska rasprostranjenost istraživanja. Institucije koje objavljuju istraživanja uključuju središnje banke (npr. središnju banku Španjolske s 4,1 %, središnju banku Francuske s 2,7 %, Europsku središnju banku s 2,7 %), međunarodne financijske institucije (Svjetska banka s 4,1 %) i sveučilišta (najveći udio ima sveučilište *Southeast University China* s 4,1 %). S obzirom na tek nedavan ozbiljniji rast interesa za ovim područjem, ne iznenađuje relativno malen broj radova po instituciji (najviše tri). S time povezano, i zastupljenost pojedinih visokoškolskih i drugih institucija treba promatrati u kontekstu relativno malog broja objavljenih radova.

Vremenska dinamika objavljenih radova. Kako bi se otkrilo kada i kako su se istraživanja u ovom području razvijala tijekom godina (Grafikon 1.), analiziran je broj radova o ESG rizicima u bankovnom poslovanju koji su objavljeni na godišnjoj razini od pojave prvih radova na tu temu (Chaumont *et al.*, 2006; Hoeppe i Gurenko, 2006). U analiziranom razdoblju (2006. – 2023.) uočen je trend rasta od 2019. godine, koji se intenzivirao u posljednjih nekoliko godina. Broj objavljenih radova povećao se u razdoblju 2020. – 2023. godine za gotovo šest puta u usporedbi s razdobljem 2006. – 2019. godine. I taj rast treba promatrati imajući u vidu relativno malen broj radova objavljivanih na godišnjoj razini u prvotnom razdoblju.

Grafikon 1. Objavljeni radovi u području ESG rizika u bankovnom poslovanju u razdoblju od 2006. do 2023. godine



Izvor: izrada autora prema bazi *Web of Science*

4.2. BIBLIOMETRIJSKA ANALIZA CITATA

Nakon deskriptivne analize, bibliometrijskom metodom dodatno su opisana, vrednovana i praćena objavljena istraživanja u području upravljanja ESG rizicima u bankovnom poslovanju te je time dopunjen deskriptivni pregled. Prvi dio bibliometrijske analize činila je analiza citata, s ciljem prikaza osnovnih karakteristika područja. Vrlo citirani radovi smatraju se važnima. Stoga je napravljen popis deset najcitiranijih radova (Tablica 3.).

Tablica 3. Značajni radovi po kriteriju citiranosti

Autor(i)	Naslov rada	Godina objave	Broj citata
Javadi i Al Masum	<i>The Impact of Climate Change on the Cost of Bank Loans</i>	2021.	51
Zioło, Filipiak, Bąk i Cheba	<i>How to Design More Sustainable Financial Systems: The Roles of Environmental, Social, and Governance Factors in the Decision-Making Process</i>	2019.	43
Keenan i Bradt	<i>Underwaterwriting: From Theory to Empiricism in Regional Mortgage Markets in the U.S.</i>	2020.	25
Nieto	<i>Banks, Climate Risk and Financial Stability</i>	2019.	22
Breitenstein, Nguyen i Walther	<i>Environmental Hazards and Risk Management in the Financial Sector: A Systematic Literature Review</i>	2021.	22
Najaf i Mostafiz	<i>Fintech Firms and Banks Sustainability: Why Cybersecurity Risk Matters?</i>	2021.	22
Hoeppe i Gurenko	<i>Scientific and Economic Rationales for Innovative Climate Insurance Solutions</i>	2006.	21
Feridun i Güngör	<i>Climate-Related Prudential Risks in the Banking Sector: A Review of the Emerging Regulatory and Supervisory Practices</i>	2020.	19
Lee, Wang, Thinh i Xu	<i>Climate Risk and Bank Liquidity Creation: International Evidence</i>	2022.	16
Lang, Ma, Mirza i Umar	<i>The Interaction of Climate Risk and Bank Liquidity: An Emerging Market perspective for transitions to low carbon energy</i>	2023.	14

Izvor: izrada autora prema bazi *Web of Science*

Među trima najcitiranijim radovima, Javadi i Al Masum (2021) nalaze empirijske dokaze da tvrtke na lokacijama s većom izloženosti klimatskim promjenama plaćaju znatno višu cijenu bankovnih kredita zbog više premije rizika. Općenito, njihovi dokazi sugeriraju da zajmodavci klimatske promjene sve više smatraju relevantnim čimbenikom rizika. Zioło *et al.* (2019), nudeći prvu ovakvu vrstu analize ESG čimbenika u financijskim odlukama, istražili su koji se ESG kriteriji ugrađuju u proces donošenja odluka financijskih instituci-

ja i također su rangirali financijske sustave u odabranim zemljama OECD-a prema kriterijima održivosti. Dobivenim poretom potvrđuju jaku poziciju skandinavskih zemalja u osiguravanju najbolje prakse održivosti u financijskim institucijama i gospodarstvu. U trećem rangiranom radu prema broju citata, Keenan i Bradt (2020) doprinose području razvojem teorijske osnove o različitim ograničenjima, informacijskim i institucionalnim, koja utječu na sudjelovanje financijskih institucija na hipotekarnim tržištima putem odobravanja plasmana koji su izloženi okolišnim čimbenicima i utjecaju klimatskih promjena. Ukazuju na ograničenja zbog kojih procijenjena izloženost riziku možda neće točno odražavati dugoročnu uspješnost imovine ili kreditni gubitak. U skladu s tom teorijom, njihovo istraživanje nudi dokaze o prijenosu rizika u određena visokorizična zemljopisna područja putem pojačane sekuritizacije hipoteka.

Spoznaje iznesene u opisanim, najcitiranijim radovima, poticaj su i drugim istraživačima za podržavanje i razvoj robusnije analize rizika povezanih s ESG čimbenicima, a posebno klimatskim promjenama, u kontekstu procjene njihova mogućeg utjecaja i negativnih posljedica koje on nosi. Općenito, financijski učinci na mikrorazini (procjena izloženosti riziku s osnove odobrenog plasmana) ili na makrorazini (stabilnost cijelog financijskog sustava) koji nastaju materijalizacijom nefinancijskih rizika koji proizlaze iz ESG čimbenika, i među njima posebno klimatskih promjena, predmet su interesa i znanstvenika i stručnjaka već neko vrijeme (npr. Weber, 2012; Georgopoulou *et al.*, 2015; Dafermos *et al.*, 2018; Battison *et al.*, 2021).

Dodatno, napravljen je i popis deset najcitiranijih autora u promatranom području (Tablica 4.). On obuhvaća autore koji su vezani uz zemlje SAD-a i europske zemlje – Poljsku, te Njemačku i Ujedinjeno Kraljevstvo. Riječ je o sveučilišnim istraživačima.

Tablica 4. Najviše citirani autori

Autor(i)	Institucija i zemlja	Broj citata
Siamak Javadi	<i>University of Texas Rio Grande Valley, SAD</i>	51
Abdullah-Al Masum	<i>University of Texas Rio Grande Valley, SAD</i>	51
Iwona Bąk	<i>West Pomeranian University of Technology Szczecin, Faculty of Economics, Poljska</i>	43
Katarzyna Cheba	<i>West Pomeranian University of Technology Szczecin, Faculty of Economics, Poljska</i>	43

Minimalan broj pojave ključnih riječi postavljen je na dva puta, a od ukupno 439 riječi, njih 66 je zadovoljilo taj kriterij. Matrice istovremenog pojavljivanja riječi dodatno su istražene te je u svrhu finalne vizualizacije korištena klaster-analiza, višedimenzionalno skaliranje i mrežna analiza. Kao ključne riječi dominantno se javljaju pojmovi *klimatski rizik* i *klimatske promjene*, koje su slijedili pojmovi *utjecaj*, *rizik*, *financijska stabilnost*, *bankarstvo*, *model*, *trošak*, *kreditni rizik* i *ulaganje*. Vizualna mapa ključnih pojmova (Prikaz 3.) pojmove koji se češće javljaju prikazuje većim kružićem i većim slovima.

Minimalna veličina klastera postavljena je na deset, te su analizom ključnih pojmova dobivena četiri klastera koji predstavljaju istraživačka polja. Iako se neke ključne riječi, koje su iste (npr. *model*) ili povezane, odnosno značenje im se preklapa (npr. *okolišni rizik* i *rizik klimatskih promjena*), javljaju u dvama različitim klasterima, moguće je prepoznati dominantne razlike i teme po klasterima. Izabrani ključni pojmovi poput *osviještenosti*, *bankarstva*, *klimatskih promjena*, *okolišnih*, *društvenih* i *upravljačkih* (ESG) čimbenika, tržišta, politika, stabilnosti upućuju na *Rast osviještenosti o važnosti ESG čimbenika i njihovu utjecaju na stabilnost bankovnih tržišta te razvoj povezanih politika* kao temu prvog klastera. Tema drugog klastera jest *Uvažavanje novih vrsta (nefinancijskih) rizika i njihova integracija u bankovne politike i sustave upravljanja rizikom radi postizanja održivog financiranja* (izabrane ključne riječi: *prilagodba*, *bankovni krediti*, *upravljanje rizicima povezanim s klimatskim promjenama*, *poslovna banka*, *kredit*, *kreditni rizik*, *odrednice*, *politike*, *održivo financiranje*). Ključne riječi u trećem klasteru (npr. *društveno odgovorno poslovanje*, *upravljanje*, *strojno učenje*, *vjerojatnost nemogućnosti naplate*, *model*, *cijena*, *otpornost*, *rizik*, *upravljanje*, *sustav*, *ranjivost*) vezane su uz temu *Razvoj modela upravljanja nefinancijskim rizicima i povećanje otpornosti banaka* u cilju preciznije procjene utjecaja nefinancijskih rizika na cijene imovine i vjerojatnosti nemogućnosti naplate potraživanja. Tema četvrtog klastera (npr. ključne riječi: *izazovi*, *tržište*, *monetarna politika*, *sistemi rizik*, *tranzicija*, *neizvjesnost*, *volatilnost*) donosi dominantno makroperspektivu, pod nazivom *Sistemi rizik*, *monetarna politika* i *tranzicija*.

4.4. BIBLIOMETRIJSKA ANALIZA ZAJEDNIČKIH CITATA

Tehnike analize zajedničkih citata koriste se za mapiranje strukture istraživačkih (pot)područja te povezivanje različitih (pot)područja, ali i za izradu pregleda aktualnih tema ili povijesnog razvoja nekog (pot)područja. Zajednički

citati oblik su povezivanja dvaju dokumenata čija se jačina povezanosti mjeri učestalošću kojom se ta dva dokumenta zajedno citiraju, a što je učestalost javljanja zajedničkih citata veća, to ukazuje na mogućnost da su ta dva rada uže povezana (Jokić, 2005). Primjena analize zajedničkih citata, koja se ubraja među najčešće korištene metode u citatnim analizama, omogućava stvaranje mapa i klastera pojedinih autora, pojedinih radova ili pojedinih izvora/časopisa. S obzirom na to da su prakse citiranja važne za dobivanje informacija o tome koje su publikacije i koje vrste istraživanja utjecale na literaturu (v. De Bakker *et al.*, 2005), analizom zajedničkih citata utvrđene su veze referenci citiranih u radovima o ESG rizicima u bankovnom poslovanju. Vizualno mapiranje referenci nalazi se u Prikazu 2. Stvaranjem mreže, odnosno klastera zajedno citiranih radova, dobiven je uvid u specifičnosti strukture znanstvenog područja upravljanja ESG rizicima u bankovnom poslovanju i povezanih komunikacija u znanosti.

Dobivena četiri klastera pokrivaju različite teme (Prikaz 2.), te je prepoznato nekoliko tema unutar pojedinog klastera. Prvi (crveni) klaster (N = 22) obuhvaća teme *klimatske promjene kao izvor financijskog rizika i vrste rizika povezanih s klimatskim promjenama*. Među istraženim temama dominiraju *utjecaj klimatskih promjena na ciljeve središnjih banaka i financijske posljedice prirodnih katastrofa na poslovanje financijskih institucija* (primjerice, na odobravanje bankovnih kredita, hipotekarno financiranje).

Drugi (zeleni) klaster je podjednake veličine (N = 18) i obuhvaća teme kao što su *karakteristike klimatskih rizika* (duboka neizvjesnost, nelinearnost, endogenost) i *izazovi integracije njihovih razmatranja u tradicionalnu procjenu ekonomskih i financijskih rizika* (npr. putem mjere klimatskog rizika na financijskom tržištu, odnosno odstupanja klimatskih promjena od prosječnih očekivanih vrijednosti – engl. *climate value at risk*, premiju za klimatski rizik, stres-testove za klimatski rizik). Nastojeći ispuniti metodološke praznine u ovom području, autori radova u ovom klasteru istražuju i teme *razvoj modela za procjenu financijskih rizika povezanih s klimatskim promjenama, ugrađivanje analiza rizika povezanih s klimom u makroekonomske i financijske analize*.

Treći (plavi) klaster (N = 17) primarno naglašava teme *financijska stabilnost, regulatorne i supervizorske prakse u kontekstu rizika povezanih s klimatskim promjenama u bankovnom poslovanju, uloga bankarstva i monetarne politike u financiranju prijelaza na niskougljično gospodarstvo te uključivanje financijskih rizika povezanih s klimatskim promjenama u financijsku politiku, uključujući okvire bonitetne, makrobonitetne i monetarne politike*. Klasterom je obuhvaće-

na i tema *objava informacija o izloženosti rizicima povezanim s klimatskim promjenama*, čime se naglašava važnost okvira izvješćivanja.


Posljednji, četvrti (žuti) klaster činili su radovi ($N = 15$) na teme *ekonomika klimatskih promjena i utjecaj čimbenika klimatskih promjena na vrednovanje financijske i realne imovine (kredita banaka, različitih vrsta obveznica, dionica, nekretnina)*, kao i *utjecaj ekološkog profila poduzeća na njegov trošak vlasničkog i dužničkog kapitala*.

Opisani klasteri pružili su uvid u različite teme u području koje su predmet interesa znanstvenika, predstavnika regulatornih i supervizorskih tijela te drugih istraživača i stručnjaka. Uzimajući u obzir pregled strukture ovog područja i njegov razvoj, intenziviran u posljednjih nekoliko godina, za očekivati je da će specifične teme u budućem razdoblju zaokupljati pozornost autora. Među objavljenim radovima, njih je nekoliko već unutar prve godine objave (2023) ostvarilo između 4 i 15 citata, istražujući teme koje će biti u fokusu budućih istraživanja. Obrađene su teme povezanosti klimatskih rizika i likvidnosti banaka (Lang *et al.*, 2023) te procjene utjecaja klimatskih promjena na hipotekarni portfelj i mobilizaciju depozita u bankovnom sektoru (Lv *et al.*, 2023). Ispitane su i mogućnosti korištenja ESG rejtinga za dobivanje informacija o rizičnosti ulaganja (Bax *et al.* 2023).

Rezultate analiza u ovom radu treba promatrati u kontekstu ograničenja istraživanja. Ona se odnose na relativno malu populaciju radova. Zatim, gotovo 60 % radova objavljeno je 2022. i 2023. godine, što otežava procjenu njihova značaja. Treće, bibliometrijsko mapiranje znanstvenog područja, iako pouzdano i korisno, najviše vrijednosti donosi kao dodatak, a ne zamjena tradicionalnom kvalitativnom pregledu literature, te se, u tom smislu, njegova isključiva upotreba može smatrati i ograničenjem istraživanja.

Ovim istraživanjem obuhvaćena je citatna baza *Web of Science* kao prvi izbor, dok bi u budućim istraživanjima bilo zanimljivo provesti i bibliometrijsku analizu koristeći se bazom *Scopus* kao također relevantnom citatnom bazom. Iako su radovi u bazi *Scopus* objavljeni u niže rangiranim časopisima i baza ne sadrži sve radove u određenom području, zbog svoje širine može koristiti pri provođenju budućih istraživanja uzimajući u obzir da je ovdje riječ o novom i još uvijek manjem istraživačkom području. Dodatno, zbog intenzivnog razvoja cjelokupnog područja održivih financija, poželjno bi bilo kontinuirano, upotrebom bibliometrijske analize, budućim istraživanjima obuhvatiti i druge njegove segmente.

Prikaz 3. Analiza zajedničkih citata referenci



5. ZAKLJUČAK

Analiza regulatornog okvira i implementacije održivosti u poslovanje ukazuje na snažan razvoj ovog područja u posljednjih nekoliko godina. Ipak, na temelju dosadašnjeg nefinancijskog izvješćivanja primijećene su značajne poteškoće zbog složenosti regulacije u području, ali i u kontekstu relativno skorog početka primjene koja u punom opsegu tek predstoji. Integracija klimatskog rizika u sustave upravljanja i izvješćivanja u financijskom sektoru s fokusom na bankovni sektor u ovom radu ukazuje na nedovoljno razumijevanje problematike, a time i poteškoće u njezinoj primjeni.

S ciljem izrade sveobuhvatnog pregleda znanstvenoistraživačkog područja ESG rizika u bankovnom sektoru, primijenjena je bibliometrijska analiza, koja je omogućila opći prikaz i specifične uvide u područje. Potvrdila je očekivanu interdisciplinarnu prirodu područja te otkrila dominaciju istraživača iz dviju velikih zemalja – Kine i SAD-a, iako se istraživanja provode i u drugim zemljama. Istaknuti su najcitiraniji radovi i autori u području ESG rizika u bankovnom sektoru, s naglaskom na sve važnije rizike povezane s klimatskim promjenama. Uvid u strukturu i razvoj područja dobiven je tumačenjem klastera literature.

Uzimajući u obzir regulatorna kretanja, kao i kretanja u znanstvenoistraživačkom području, u narednom razdoblju očekuje se šira i složenija primjena

analize i integracije klimatskih rizika u bankovno poslovanje, što će postaviti temelje za kvalitetnije upravljanje ESG rizicima u financijskom sektoru.

REFERENCE

1. Azmi, W., Hassan M. K., Houston, R. i Karim, M. S. (2021) ESG activities and banking performance: International evidence from emerging economies, *Journal of International Financial Markets, Institutions and Money*, Vol. 70, str. 101277.
2. Battison, S., Dafermos, Y. i Monasterolo, I. (2021) Climate risks and financial stability, *Journal of Financial Stability*, Vol. 54, str. 100867.
3. Bax, K., Sahin, Ö., Czado, C. i Paterlini, S. (2023) ESG, Risk, and (tail) dependence, *International Review of Financial Analysis*, Vol. 87, str. 102513.
4. Breitenstein, M., Nguyen, D. K. i Walther, T. (2021) Environmental hazards and risk management in the financial sector: A systematic literature review, *Journal of Economic Surveys*, Vol. 35, No. 2, str. 512-538.
5. Caplan, L., Griswold, J. S. i Jarvis, W. F. (2013) *From SRI to ESG, The Changing World of Responsible Investing*, Commonfund Institute.
6. Chaumont, S., Imkeller, P. i Müller, M. (2006) Equilibrium trading of climate and weather risk and numerical simulation in a Markovian framework, *Stochastic Environmental Research and Risk Assessment*, Vol. 20, No. 3, str. 184-205.
7. Courtial, J. P., Callon, M. i Sigogneau, A. (1993) The use of patent titles for identifying the topics of invention and forecasting trends. *Scientometrics*, Vol. 26, No. 2, str. 231-242.
8. Dafermos, Y., Nikolaidi, M. i Galanis, G. (2018) Climate Change, Financial Stability and Monetary Policy, *Ecological Economics*, Vol. 152, str. 219-234.
9. De Bakker, F. G. A., Groenewegen, P. i Den Hond, F. (2005) A bibliometric analysis of 30 years of research and theory on corporate social responsibility and corporate social performance, *Business & society*, Vol. 44, No. 3, str. 283-317.
10. De Giuli, M. E., Grechi, D. i Tanda, A. (2023) What do we know about ESG and risk? A systematic and bibliometric review, *Corporate Social Responsibility and Environmental Management*, Early View, <https://doi.org/10.1002/csr.2624>
11. Ernst & Young (2022) *ESG Introduction & Taxonomy*. Dostupno na: https://assets.ey.com/content/dam/ey-sites/ey-com/cs_cz/topics/financial-services/ey-vse-esg-2022_day1.pdf?download [15. listopada 2023.]
12. European Banking Authority (2019) *EBA Action Plan on Sustainable Finance*. Dostupno na: https://www.eba.europa.eu/sites/default/documents/files/document_library/EBA%20Action%20plan%20on%20sustainable%20finance.pdf?retry=1 [20. studenoga 2023.]
13. European Banking Authority (2021) *EBA Report on Management and Supervision of ESG Risks for Credit Institutions and Investment Firms*, EBA/REP/2021/18

14. European Banking Authority (2022a) *Final draft implementing technical standards on prudential disclosures on ESG risks in accordance with Article 449a CRR*, EBA/ITS/2022/01
15. European Banking Authority (2022b) Report on Incorporating ESG Risks in the Supervision of Investment Firms Report Complementing EBA/REP/2021/18, EBA/REP/2022/26
16. European Banking Authority (2022c) The role of environmental risks in the prudential framework discussion paper, EBA/DP/2022/02
17. European Central Bank (2020) *ECB Guide on climate-related and environmental risks*, Dostupno na: <https://www.bankingsupervision.europa.eu/ecb/pub/pdf/ssm.202011finalguideonclimate-relatedandenvironmentalrisks~58213f6564.en.pdf> [20. studenoga 2023.]
18. European Central Bank (2021) *Climate risk stress test SSM stress test 2022*. Dostupno na: <https://www.bankingsupervision.europa.eu/ecb/pub/pdf/ssm.climateriskstress-test2021~a4de107198.en.pdf> [20. studenoga 2023.]
19. European Central Bank (2022a) *2022 Climate risk stress test*. Dostupno na: https://www.bankingsupervision.europa.eu/ecb/pub/pdf/ssm.climate_stress_test_report.20220708~2e3cc0999f.en.pdf [20. studenoga 2023.]
20. European Central Bank (2022b) *ECB report on good practices for climate stress testing*, Dostupno na: https://www.bankingsupervision.europa.eu/ecb/pub/pdf/ssm.202212_ECBreport_on_good_practices_for_CST~539227e0c1.en.pdf
21. Europska komisija (2021) *Strategija za financiranje tranzicije prema održivom gospodarstvu*. Dostupno na: https://eur-lex.europa.eu/resource.html?uri=cellar:9f5e7e95-df06-11eb-895a-01aa75ed71a1.0002.02/DOC_1&format=PDF [15. listopada 2023.]
22. Feridun, M. i Güngör, H. (2020). Climate-related prudential risks in the banking sector: A review of the emerging regulatory and supervisory practices. *Sustainability*, 12(13), str. 5325.
23. Gaganis, C., Pasiouras, F., Tasiou, M. i Zopounidis, C. (2023) *Sustainable Finance and ESG: Risk, Management, Regulations, and Implications for Financial Institutions*, Palgrave MacMillan Studies in Banking and Financial Institutions, Springer Nature Switzerland (e-knjiga). Dostupno na: <https://doi.org/10.1007/978-3-031-24283-0> [15. listopada 2023.]
24. Galletta, S., Mazzù, S. i Naciti, V. (2022). A bibliometric analysis of ESG performance in the banking industry: From the current status to future directions. *Research in International Business and Finance*, Vol. 62(C), str. 101684.
25. Galletta, S., Goodell, J. W., Mazzù, S. i Paltrinieri, A. (2023) Bank reputation and operational risk: The impact of ESG, *Finance Research Letters*, Vol. 51, str. 103494.
26. Georgopoulou, E., Mirasgedis, S., Sarafidis, Y., Hontoub, V., Gakis, N., Lalas, D., Xenoyianni, F., Kakavoulis, N., Dimopoulos, D. i Zavras, V. (2014) A methodological framework and tool for assessing the climate change related risks in the banking sector, *Journal of Environmental Planning and Management*, Vol. 58, No. 5, str. 874–897.

27. Hoeppe, P. i Gurenko, E. N. (2006) Scientific and economic rationales for innovative climate insurance solutions, *Climate Policy*, Vol. 6, No. 6, str. 607-620.
28. Ivanišević Hernaus, A. (2016) What is Social in Finance?, *Proceedings of the 8th International Conference „An Enterprise Odyssey: Saving the Sinking Ship Through Human Capital“*, University of Zagreb, Faculty of Economics and Business, str. 559-567.
29. Javadi, S. i Al Masum, A. (2021) The impact of climate change on the cost of bank loans, *Journal of Corporate Finance*, 69, str. 102019.
30. Jokić, M. (2005) *Bibliometrijski aspekti vrednovanja znanstvenog rada*. Sveučilišna knjižara: Zagreb.
31. Kalfaoglou, F. (2021) ESG risks: a new source of risks for the banking sector, *Bank of Greece Economic Bulletin*, (53).
32. Keenan, J. M. i Bradt, J. T. (2020) Underwaterwriting: from theory to empiricism in regional mortgage markets in the U.S., *Climatic Change*, Vol. 62, No. 2.
33. Lang, Q., Ma, F., Mirza, N. i Umar, M. (2023) The interaction of climate risk and bank liquidity: An emerging market perspective for transitions to low carbon energy, *Technological Forecasting and Social Change*, Vol. 191, str. 122480.
34. Lee, C. C., Wang, C. W., Thinh, B. T. i Xu, Z. T. (2022). Climate risk and bank liquidity creation: International evidence. *International Review of Financial Analysis*, 82, str. 102198.
35. Lv, W., Mirza, N., Umar, M. i Chen, W. (2023) The Nexus of climate crisis and asset liability management in frontier economies, *Technological Forecasting and Social Change*, Vol. 192, str. 122586.
36. Najaf, K., Mostafiz, M. I. i Najaf, R. (2021). Fintech firms and banks sustainability: why cybersecurity risk matters?. *International Journal of Financial Engineering*, 8(02), str. 2150019.
37. Nieto, M.J. (2019) Banks, climate risk and financial stability, *Journal of Financial Regulation and Compliance*, Vol. 27 No. 2, str. 243-262.
38. Nitescu, D.-C. i Cristea, M.-A. (2020) Environmental, Social and Governance Risks – New Challenges for the Banking Business Sustainability, *Amfiteatru Economic*, Vol. 22, No. 55, str. 692-706.
39. OECD (2019) The OECD Glossary of Statistical Terms, <https://stats.oecd.org/glossary/>
40. Pitchbook (2021) The key differences between SRI, ESG and impact investing, Dostupno na: <https://pitchbook.com/blog/what-are-the-differences-between-sri-esg-and-impact-investing> [15. listopada 2023.]
41. Rey-Martí, A., Ribeiro-Soriano, D. i Palacios-Marqués, D. (2016) A bibliometric analysis of social entrepreneurship, *Journal of Business Research*, Vol. 69, No. 5, str. 1651-1655.
42. Službeni list EU (2013) Direktiva 2013/36/EU o pristupanju djelatnosti kreditnih institucija i bonitetnom nadzoru nad kreditnim institucijama i investicijskim društvima
43. Službeni list EU (2013) Uredba (EU) 575/2013 o bonitetnim zahtjevima za kreditne institucije i investicijska društva

44. Službeni list EU (2014) Direktiva 2014/95/EU Europskog parlamenta i Vijeća od 22. listopada 2014. o izmjeni Direktive 2013/34/EU u pogledu objavljivanja nefinancijskih informacija i informacija o raznolikosti određenih velikih poduzeća i grupa
45. Službeni list EU (2017) Direktiva (EU) 2017/828 Europskog parlamenta i Vijeća od 17. svibnja 2017. o izmjeni Direktive 2007/36/EZ u pogledu poticanja dugoročnog sudjelovanja dioničara
46. Službeni list EU (2019) Direktiva 2019/878/EU o izmjeni Direktive 2013/36/EU u pogledu izuzetih subjekata, financijskih holdinga, mješovitih financijskih holdinga, primitaka, nadzornih mjera i ovlasti te mjera za očuvanje kapitala
47. Službeni list EU (2019) Uredba (EU) 2019/2088 Europskog parlamenta i Vijeća od 27. studenoga 2019. o objavama povezanim s održivosti u sektoru financijskih usluga
48. Službeni list EU (2019) Uredba (EU) 2019/2089 Europskog parlamenta i Vijeća od 27. studenoga 2019. o izmjeni Uredbe (EU) 2016/1011 u pogledu referentnih vrijednosti EU-a za klimatsku tranziciju i referentnih vrijednosti EU-a usklađenih s Pariškim sporazumom te objavama u vezi s održivošću za referentne vrijednosti
49. Službeni list EU (2019) Uredba (EU) 2019/876 o izmjeni Uredbe (EU) br. 575/2013 u pogledu omjera financijske poluge, omjera neto stabilnih izvora financiranja, zahtjeva za regulatorni kapital i prihvatljive obveze, kreditnog rizika druge ugovorne strane, tržišnog rizika, izloženosti prema središnjim drugim ugovornim stranama, izloženosti prema subjektima za zajednička ulaganja, velikih izloženosti, zahtjeva za izvješćivanje i objavu, i Uredbe (EU) br. 648/2012
50. Službeni list EU (2020) Uredba (EU) 2020/852 Europskog parlamenta i Vijeća od 18. lipnja 2020. o uspostavi okvira za olakšavanje održivih ulaganja i izmjeni Uredbe (EU) 2019/2088
51. Službeni list EU (2022) Direktiva (EU) 2022/2464 Europskog parlamenta i Vijeća od 14. prosinca 2022. o izmjeni Uredbe (EU) br. 537/2014, Direktive 2004/109/EZ, Direktive 2006/43/EZ i Direktive 2013/34/EU u pogledu korporativnog izvješćivanja o održivosti
52. Tuškan Sjauš, B., Zlovolić, M. i Krišto, J. (2023) Implikacije društvenog čimbenika u okviru održivog i odgovornog poslovanja i ulaganja. *Ekonomska misao i praksa* (u postupku objave), Dostupno na: <https://hrcak.srce.hr/307515>
53. Tuškan, Sjauš, B. (2022) Održiva i odgovorna financijska ulaganja, poglavlje u knjizi *Suvremene financijske usluge: razvojni pravci i strateška pitanja* (ed. Stojanović, A.), Ekonomski fakultet: Zagreb, str. 408-462.
54. Weber, O. (2012) Environmental Credit Risk Management in Banks and Financial Service Institutions, *Business Strategy and the Environment*, 21, str. 248-263.
55. Ziolo, M., Filipiak, B. Z., Bak, I. i Cheba, K. (2019) How to Design More Sustainable Financial Systems: The Roles of Environmental, Social, and Governance Factors in the Decision-Making Process, *Sustainability*, 11, str. 5604.
56. Zupic, I. i Čater, T. (2015) Bibliometric Methods in Management and Organization, *Organizational Research Methods*, Vol. 18, No. 3, str. 429-472.

ESG RISKS IN THE BANKING SECTOR: A BIBLIOMETRIC LITERATURE ANALYSIS

Associate Professor Ana Ivanišević Hernaus, PhD

University of Zagreb Faculty of Economics and Business

e-mail: aivanisev@net.efzg.hr

Associate Professor Branka Tuškan Sjauš, PhD

University of Zagreb Faculty of Economics and Business

e-mail: btuskan@net.efzg.hr

ABSTRACT

The development of the regulatory framework and the associated strong growth of interest in sustainable business practices have encouraged the inclusion of environmental, social, and governance (ESG) factors in the operations of financial and non-financial entities. Sustainable business practices have highlighted the necessity of monitoring and managing ESG risks, with a particular emphasis on climate risk, which is the focus of this paper. The purpose of the paper is to highlight recent trends in the EU regulatory framework and the development of the related scientific research field. The paper presents a systematized overview of recent regulatory achievements, with a special focus on the banking sector, as content analysis of supervisory announcements has revealed an insufficient understanding of ESG risks by market participants and their integration into business operations. A bibliometric analysis provides an overview of the development and structure of the scientific research field, confirming its interdisciplinary nature. The results offer insights into significant papers, the most cited authors, and sources relevant for publishing research, and enable the identification of key topics and development directions in this area.

Key words: ESG risks, climate risk, regulation, banks, bibliometric analysis

JEL classification: G15; G21; M14; O16



DIO 3: FINANCIJSKA STABILNOST I KRIZNE SITUACIJE

PREDVIĐANJE FINACIJSKE NESTABILNOSTI ODABRANIH POSLOVNIH SUBJEKATA U POSTPANDEMIJSKOM RAZDOBLJU

izv. prof. dr. sc. Siniša Bogdan

Sveučilište u Rijeci, Fakultet za menadžment u turizmu i ugostiteljstvu
e-mail: sinisab@fthm.hr

SAŽETAK

Svrha ovog rada jest procijeniti modele za predviđanje financijskih nestabilnosti poslovnih subjekata analizom različitih sektora u Republici Hrvatskoj, posebice u postpandemijskom razdoblju. Fokus će biti na sektorima građevinarstva, prerađivačke industrije i trgovine, s ciljem određivanja značajnih financijskih pokazatelja za svaki od navedenih sektora. U radu je financijska nestabilnost definirana blokadom poslovnog subjekta u trajanju jednakom ili višem od 60 dana. Promatrani period odnosio se na postpandemijsko razdoblje: 1. 1. 2022. – 16. 12. 2023. Na temelju primijenjene logističke regresije, odnosno stepwise forward LR procedure determinirani su prediktivni modeli za sve tri djelatnosti, te je testirana točnost predviđanja za pet godina prije ulaska poslovnog subjekta u blokadu. Rezultati sugeriraju da su: koeficijent vlastitog financiranja i dani plaćanja dobavljačima kao nezavisne varijable prisutni u svim trima modelima, dok je EBITDA marža prisutna samo u modelu za predviđanje financijskih poteškoća poslovnih subjekata unutar građevinske djelatnosti. Sva su tri modela unutar prve tri godine iskazala točnost predviđanja u rasponu 77.3 – 87.0 %, što se smatra zadovoljavajućim rezultatom. Na temelju dobivenih rezultata nužno je napomenuti da modelima eksponencijalno opada točnost predviđanja nestabilnih poslovnih subjekata nakon treće godine, te se ujedno ne sugerira korištenje modela za razdoblje duže od tri godine.

Ključne riječi: *blokada, stečaj, financijske poteškoće, logit.*

JEL klasifikacija: G33, G34

1. UVOD

Hrvatsko se gospodarstvo tijekom pojave pandemije koronavirusa u 2020. godini suočilo s velikim padom. Pad bi bio još i veći da brojne državne mjere nisu ublažile vrlo nepovoljnu situaciju. Sada, u postpandemijskom razdoblju, značajan broj poslovnih subjekata našao se u financijskim poteškoćama iz različitih makro ili mikroekonomskih razloga. Kako je vrlo zahtjevno obuhvatiti sve djelatnosti, u ovome radu odabrane su građevinska, prerađivačka, te trgovinska djelatnost u cilju otkrivanja značajnih financijskih pokazatelja koji bi mogli poslužiti kao indikatori u modelu koji ima mogućnost ranog otkrivanja financijskih poteškoća. Prema podacima Financijske agencije u razdoblju od 1. 1. 2022. - 16. 12. 2023. prema kriteriju blokade u razdoblju jednakom ili većem od 60 dana, ukupno je 17 327 poslovnih subjekata blokirano, od čega 3461 u djelatnosti G - Trgovine na veliko i malo; popravak motornih vozila i motocikala, 3048 u djelatnosti F - građevinarstvo, te 1769 subjekta u području C - prerađivačka industrija. Navedene tri djelatnosti zajedno čine 47.8 % ukupno blokiranih subjekata u odnosu na ukupan broj blokiranih poslovnih subjekata u promatranom razdoblju. Unutar navedenih triju djelatnosti po značajnom broju blokiranih poslovnih subjekata mogla bi se uključiti i I - djelatnost pružanja smještaja te pripreme i usluživanja hrane s ukupnim brojem od 2949 poslovnih subjekata. Ovdje je riječ o poslovnim subjektima različitih veličina, dok se u radu koristio isključivo uzorak koji su činili mali i srednji poslovni subjekti.

Gledajući svaku od promatranih djelatnosti posebno, može se zaključiti da prerađivačka djelatnost ima krucijalnu ulogu u gospodarstvima diljem svijeta, time i Hrvatske, a posebno je ranjiva bila u vrijeme koronakrize zbog kašnjenja isporuka sirovina, poluproizvoda, rasta cijena proizvoda i prijevoza, produljenja naplate potraživanja, pada narudžbi, što je impliciralo kod dijela poslovnih subjekata financijske poteškoće i u razdoblju nakon pandemije. S druge strane, građevinski sektor pokazao je solidnu otpornost prema različitim negativnim čimbenicima kao što su, recesija, rast sirovina, pandemija, problemi s pronalaskom radne snage, što je svakako pozitivna informacija jer značajno doprinosi sveukupnom hrvatskom gospodarstvu. Također je važno napomenuti da za razliku od zemalja EU-a zasad nije pokazao znakove značajnijeg usporavanja, no velik broj prisutnih poslovnih subjekata unutar djelatnosti građevinarstva na tržištu se ipak nije mogao nositi s danim izazovima na temelju čega su po broju blokada poslovni subjekti navedene djelatnosti zasjeli na samo čelo ljestvice. Visoka stopa inflacije u 2022. godini svakako je obilježila godinu te značajno umanjila kupovnu moć potrošača kada se govori o kretanjima unutar trgovin-

ske djelatnosti. Prema izvještaju Ekonomskog instituta (2023) iako je smanjen broj maloprodavača u 2022. godini, turistička sezona i pozitivni trendovi na tržištu rada imali su pozitivan efekt na samu djelatnost, no Hrvatska u navedenom segmentu na temelju većine financijskih indikatora uspješnosti zaostaje za prosjekom EU-a, a značajan je i broj poslovnih subjekata koji 60 ili više dana bilježe blokadu u promatranom periodu.

Predviđanje financijskih poteškoća kao tema, predmet je akademskog istraživanja još od početka dvadesetog stoljeća. Među prvim radovima koji su izučavali navedenu problematiku bili su Ramser i Foster (1931), Fitzpatrick (1932), te Winakor i Smith (1935). Do veće popularizacije izučavanja tematike predviđanja stečaja i sličnih tema u akademskim krugovima došlo je nakon inicijalne objave Altmanova (1968) rada vezanog uz predviđanje stečaja i modeliranja pokazatelja za predviđanje stečaja pod nazivom „z-score“. Mjera u kojoj je navedena tematika održala popularnost u narednim godinama svjedoče i noviji radovi Altman (1983, 2018), te Altman *et al.* (1977, 1995, 2013, 2014). Osim Edwarda Altmana, značajan je doprinos i ostalih autora koji su doprinijeli tematici predviđanja financijskih poteškoća, odnosno stečaja ovisno o pojedinačnom tumačenju autora kao što su: Edmister, 1972; Wilcox, 1973; Blum, 1974; Ohlson 1980, te Dimitras *et al.*, 1999 itd. Tehnike koje su bile primjenjivane do 80-ih godina uglavnom su se odnosile na diskriminacijsku analizu. Prema Sajter (2009), Ohlson (1980) je korištenjem logit modela odlučio napraviti zaokret, nakon čega je navedena metodologija ujedno dobila na popularnosti u predviđanju financijskih poteškoća, odnosno stečaja. Osim logit metode, na popularnosti je upravo zbog jednostavnosti korištenja postala značajna i probit metoda (Zmijewski 1984; Zavgren 1985; Bernhardsen 2001; Kovavoca i Kliestik 2017 i ostali). Tijekom narednog razdoblja problematika predviđanja financijskih poteškoća bila je proučavana brojnim metodama kao što su metoda višestrukih klasifikatora, neuralne mreže, metoda potpornih vektora, duboke neuronske mreže i sl. Proučavanje problematike predviđanja financijskih poteškoća u akademskim krugovima konstantno je prisutno, interes za samom temom uvećao se nakon 2008 godine i svjetske financijske krize (Shi i Li, 2019). Iako danas postoji respektabilan broj različitih metoda za predviđanje stečaja, isti autori ističu logističku regresiju i neuralne mreže kao najučestalije korištene metode u predviđanju stečaja promatrajući pritom razdoblje od 1968. do 2017. godine

Veći broj akademskih radova argumentira razloge po kojima neuralne mreže mogu s većom točnošću predviđati financijske poteškoće u odnosu na logističku regresiju, no postoje i radovi koji tvrde suprotno kao što su: Etheridge i Sriram

(1997), Kristanti i Dhaniswara (2023), te Muparuri i Gumbo (2022). Osim stranih autora koji doprinose boljem razumijevanju predviđanja problematike financijskih poteškoća poslovnih subjekata, značajan je doprinos i domaćih autora u istome području. Neki od domaćih autora koji su primjenom metoda multiple diskriminantne analize i logističke regresije definirali različite modele koji bi služili kao sustav ranog upozorenja za financijske poteškoće jesu: Novak i Crnković (2007), Sajter (2008), Šarlija i Jeger (2011), Ježovita (2015) te Bogdan (2021).

Ovaj rad strukturiran je sukladno IMRAD strukturi, odnosno nakon uvoda slijedi poglavlje s podacima i metodologijom, gdje su na detaljan način opisani uzorak, financijski indikatori koji su korišteni u analizi, te korištena metodologija. Nakon navedenog poglavlja u istraživačkom dijelu predstavljeni su rezultati istraživanja, testirane su pretpostavke modela, mjere prikladnosti, te je u istom poglavlju testirana točnost predviđanja modela. U posljednjem dijelu sintetizirane su zaključne misli, te su iskazana ograničenja istraživanja i preporuke za buduća istraživanja.

2. PODACI I METODOLOGIJA

Cilj ovog istraživanja odnosi se na pronalazak modela za predviđanje financijskih poteškoća poslovnih subjekata odabranih djelatnosti u Republici Hrvatskoj. U ovome radu na temelju dostupnih podataka Financijske agencije (FINA) odabrana su mala i srednja poduzeća iz triju različitih područja kako slijedi: prerađivačke djelatnosti, građevinarstva, te djelatnosti trgovine na veliko i malo, popravak motornih vozila i motocikala. Odabrane industrije su na datum pretrage imale status blokade jednako ili više od 60 dana unutar razdoblja 1. 1. 2022. - 16. 12. 2023. godine. Sukladno klasifikaciji objavljenoj na službenim stranicama FINA-e, djelatnost građevinarstva, te trgovine na veliko i malo, popravka motornih vozila i motocikala bilježe najveći broj poslovnih subjekata s blokadom prema zadanim parametrima, dok djelatnost prerađivačke industrije također pripada u prve četiri djelatnosti s najvećim brojem poslovnih subjekata koji su zabilježili blokadu unutar promatrane djelatnosti. Što se tiče odabira broja dana u blokadi sukladno Stečajnom zakonu (NN 71/15, 104/17, 36/22) čl. 110 st. 1:

„Financijska agencija dužna je podnijeti prijedlog za otvaranje stečajnog postupka ako pravna osoba u Očevidniku redoslijeda osnova za plaćanje ima evidentirane neizvršene osnove za plaćanje u neprekinutom razdoblju od 120 dana, u roku od osam dana od isteka toga razdoblja, osim ako su ispunjene pretpostavke iz članka 428. Stečajnog zakona.“

Budući da je uzorak broja poslovnih subjekata u blokadi za promatranje bio nedostatan ako bi se promatrale djelatnosti s blokadom jednakom ili većom od 120 dana u zadanom razdoblju, navedeni broj dana umanjen je na 60 dana, na temelju čega je za svaku odabranu djelatnost dobiven reprezentativan uzorak poslovnih subjekata. Budući da je cilj bio promatranje poslovnih subjekata u postpandemijskom razdoblju, odabrano je razdoblje 1. 1. 2022. - 16. 12. 2023. godine. Kako bi se kreirao model koji bi mogao služiti kao svojevrsan alarm, te koji bi se mogao koristiti za rano upozorenje od stečaja, uzorak poslovnih subjekata koji imaju poteškoće promatrao se godinu dana prije godine unutar koje je započela blokada za određeni poslovni subjekt. Osim poslovnih subjekata koji imaju poslovnih poteškoća, u uzorku su se koristili i poslovni subjekti unutar iste djelatnosti, koji imaju stabilno poslovanje. Preciznije, za uzorak poslovnih subjekata koje obilježava „stabilno poslovanje“ korišteni su oni koji prema klasifikaciji FINA-e imaju kreditni rejting A1 – poduzetnici sa zanemarivom vjerojatnošću zastoja u plaćanju, A2 – poduzetnici s najnižom vjerojatnošću zastoja u plaćanju, te A3 – poduzetnici s vrlo niskom vjerojatnošću zastoja u plaćanju. Uzorak poslovnih subjekata na temelju kojih će se model procijeniti, te ujedno na temelju kojega će se testirati njegova točnost predviđanja, temeljen je na sljedećem broju poslovnih subjekata:

Tablica 1. Uzorak poslovnih subjekata koji je korišten u kreiranju i testiranju prediktivnih mogućnosti modela za predviđanje financijskih poteškoća poslovnih subjekata.

God. prije blokade		Prerađivačka industrija	Građevinarstvo	Trgovine na veliko i malo, popravak motornih vozila i motocikala
t-1	Stabilni	126	124	130
	Nestabilni	78	80	79
t-2	Stabilni	126	124	130
	Nestabilni	71	75	69
t-3	Stabilni	126	124	127
	Nestabilni	67	66	57
t-4	Stabilni	125	123	127
	Nestabilni	53	53	37
t-5	Stabilni	124	121	122
	Nestabilni	32	23	26

Izvor: izrada autora

Brojevi poslovnih subjekata kako je prikazano u Tablici 1., osciliraju prema godinama jer su neki od subjekata bili prisutni na tržištu kraće od pet godina, za neke poslovne subjekte podaci nisu bili dostupni, dok su neki poslovni su-

bjekti imali financijske podatke koji su u ekstremnoj mjeri odstupali od prosjeka (engl. *outliers*), te su takvi poslovni subjekti bili uklonjeni iz uzorka kako njihov utjecaj ne bi narušio točnost modela.

Financijski pokazatelji koji su korišteni kao nezavisne varijable prikazani su u Tablici 2.

Tablica 2. Financijski pokazatelji korišteni u izradi modela

Varijabla	Opis	Financijski pokazatelj
Q1	Novac u banci i blagajni / kratkoročne obveze	likvidnosti
Q2	(Kratkotrajna imovina – zalihe) / kratkoročne obveze	likvidnosti
Q3	Kratkotrajna imovina / kratkoročne obveze	likvidnosti
S4	Dugotrajna imovina / (kapital i rezerve + rezerviranja + dugoročne obveze)	financijske stabilnosti
L1	(Dugoročne obveze + kratkoročne obveze) / ukupno aktiva	poluge
L2	(Kapital i rezerve + rezerviranja) / ukupno aktiva	poluge
L3	(Dugoročne obveze + kratkoročne obveze) / (kapital i rezerve + rezerviranja)	poluge
L4	(Dugoročne obveze + kratkoročne obveze) / (zadržana dobit + amortizacija)	poluge
L5	((Kapital i rezerve + rezerviranja) / dugotrajna imovina) * 100	poluge
L6	((Kapital i rezerve + rezerviranja + dugoročne obveze) / dugotrajna imovina) * 100	poluge
A1	Ukupni prihodi / ukupna imovina	aktivnosti
A2	Ukupni prihodi / kratkotrajna imovina	aktivnosti
A3	$365 * (\text{kratkoročna potraživanja} / \text{poslovni prihodi})$	aktivnosti
A4	$365 * (\text{potraživanja od kupaca} / \text{prihodi od prodaje})$	aktivnosti
A5	$365 * ((\text{obveze prema dobavljačima}) / (\text{ukupni rashodi} - \text{financijski rashodi}))$	aktivnosti
P1	$(\text{Ukupni prihodi} / \text{ukupni rashodi}) * 100$	profitabilnosti
P2	$(\text{Poslovni prihodi} / \text{poslovni rashodi}) * 100$	profitabilnosti
P3	$(\text{Dobit ili gubitak prije oporezivanja} / \text{ukupni prihodi}) * 100$	profitabilnosti
P4	$(\text{Dobit ili gubitak razdoblja} / \text{ukupni prihodi}) * 100$	profitabilnosti
P5	$(\text{Dobit ili gubitak prije oporezivanja} / \text{ukupno aktiva}) * 100$	profitabilnosti
P6	$(\text{Dobit ili gubitak razdoblja} / \text{ukupno aktiva}) * 100$	profitabilnosti
P7	$(\text{Dobit ili gubitak razdoblja} / \text{kapital i rezerve}) * 100$	profitabilnosti
P8	$((\text{Poslovni prihodi} - \text{poslovni rashodi}) / \text{poslovni prihodi}) * 100$	profitabilnosti
P9	$((\text{Poslovni prihodi} - \text{poslovni rashodi} + \text{amortizacija}) / \text{poslovni prihodi}) * 100$	profitabilnosti

Izvor: tablica prilagođena na temelju www.fina.hr (pristupljeno 15. 11. 2023.)

Metodologija koja je korištena u procjeni modela temelji se na logističkoj regresiji. Logistička regresija predstavlja metodu koja se koristi u slučajevima kada je zavisna varijabla binarna, odnosno u konkretnom slučaju ovoga rada, 1 predstavlja poslovni subjekt koji je u blokadi, dok 0 predstavlja poslovni subjekt koji ima stabilno poslovanje. Odnos zavisnih i vektorskih nezavisnih varijabli jest nelinearan, te je funkcija u obliku slova „S“ s asimptotama 0 i 1 (Šošić 2006, str. 488). Općeniti oblik jednadžbe predstavlja:

$$P(Y = 1|x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_n x_n + \varepsilon)}} \quad (1)$$

Izraz $P(Y=1 | x)$ predstavlja vjerojatnost da će zavisna varijabla biti jednaka 1, što će se temeljiti na vrijednostima neovisnih varijabli $x_1, x_2, \dots, x_n$. Odnosno, konkretnije, prema zadanom modelu poslovni subjekti koji će imati P vrijednost veću od 0.5 klasificirat će se kao poslovni subjekt koji ima financijskih poteškoća, dok oni subjekti koji će istu vrijednost imati manju od 0.5 klasificirat će se kao poslovni subjekti sa stabilnim poslovanjem. U radu je korišten „stepwise forward lr“ pristup unutar kojeg su determinirani kriteriji prema kojima su varijable postupno dodavane u model u cilju poboljšanja njegove statističke značajnosti. Za razliku od linearne regresije pretpostavke o normalnosti reziduala, homoskedastičnosti, linearnosti nisu relevantne kod logističke regresije, dok multikolinearnost između nezavisnih varijabli svakako treba izbjegnuti, a postoje i testovi koji determiniraju u kojoj mjeri model „odgovara“ podacima, što je detaljno elaborirano u sljedećem poglavlju.

3. REZULTATI ISTRAŽIVANJA

U prvom koraku procijenjeni su korelacijski koeficijenti za sve tri djelatnosti u cilju nenarušavanja pretpostavke koja se odnosi na multikolinearnost nezavisnih varijabli za sve tri različite djelatnosti. Korelacijske matrice moguće je provjeriti u prilogu 1, 2 i 3. Kako bi se izbjegao problem multikolinearnosti između nezavisnih varijabli, određene su varijable koje su imale visoki koeficijent korelacije uklonjene. Kako bi se utvrdilo je li problem multikolinearnosti i dalje prisutan testiran je faktor inflacije varijance – VIF (engl. *Variance inflation factor*). U konkretnom slučaju VIF će biti jednak 5 ili višoj vrijednosti ako problem multikolinearnosti nije izbjegnut. Prema rezultatima koje je moguće pogledati u prilogu 4, vidljivo je da je ova pretpostavka zadovoljena, odnosno da varijable nisu međusobno kolinearne.

U sljedećem koraku na temelju logističke regresije i *stepwise* procedure odabira unaprijed razvijeni su modeli za sve tri djelatnosti, odnosno: građevinsku, prerađivačku te trgovinsku djelatnost. Uzorak koji se koristio za razvijanje modela sastojao se od stabilnih i nestabilnih poslovnih subjekata. Kod nestabilnih poslovnih subjekata uzeti su godišnji financijski izvještaji godinu dana prije godine unutar koje je nastupila blokada, te je ta godina ujedno poslužila za razvoj modela, dok je prediktivna sposobnost modela testirana na drugoj, trećoj, četvrtoj i petoj godini prije blokade.

Tablica 3. Značajne nezavisne varijable za građevinsku djelatnost.

Varijable	B	S. E.	Wald	df	Sig.	Exp (B)
L2	-4.100	0.846	23.507	1	0.000	0.017
A5	0.011	0.004	7.317	1	0.007	1.011
P9	-0.033	0.014	5.363	1	0.021	0.968
konstanta	0.453	0.451	1.011	1	0.315	1.573

Izvor: izrada autora

Tablica 4. Značajne nezavisne varijable za prerađivačku djelatnost.

Varijable	B	S. E.	Wald	df	Sig.	Exp (B)
L2	-4.243	0.794	28.525	1	0.000	0.014
A5	0.014	0.005	8.459	1	0.004	1.014
konstanta	0.404	0.413	0.958	1	0.328	1.498

Izvor: izrada autora

Tablica 5. Značajne nezavisne varijable za trgovinsku djelatnost.

Varijable	B	S. E.	Wald	df	Sig.	Exp (B)
L2	-4.007	0.822	23.748	1	0.000	0.018
A5	0.020	0.005	17.694	1	0.000	1.020
konstanta	-0.127	0.355	0.128	1	0.721	0.881

Izvor: izrada autora

Na temelju dobivenih signifikantnih varijabli može se zaključiti da sve tri djelatnosti u svom modelu imaju prisutan financijski pokazatelj L_2 - koeficijent vlastitog financiranja i A_5 koji predstavlja dane plaćanja dobavljačima. Na temelju koeficijenta vlastitog financiranja može se zaključiti u kojoj mjeri poslovni subjekt financira svoju imovinu iz vlastitih sredstava, što je udio manji, to je ujedno i veća vjerojatnost da će poslovni subjekt imati poslovnih poteškoća. Manji broj dana plaćanja dobavljačima može ukazivati da poslovni subjekt redovitije podmiruje svoje obveze. Veći broj dana može ukazivati na to da se

poslovni subjekt u većoj mjeri oslanja na financiranje na temelju dobavljača, što ujedno može ukazivati na probleme s likvidnošću i solventnošću. Model namijenjen građevinskoj djelatnosti osim pokazatelja L_2 i A_5 , sadrži i pokazatelj P_9 koji predstavlja EBITDA maržu, navedeni pokazatelj označava mjeru operativne profitabilnosti, gdje je isključen utjecaj kamata, poreza te stavki amortizacije i deprecijacije kako bi se procijenila profitabilnost poslovnog subjekta. Na temelju dobivenih rezultata u tablicama 3., 4. i 5., može se zaključiti da su nezavisne varijable u svim trima tablicama statistički značajne $p < 0.05$. Osim toga, predznaci beta koeficijenata slijede financijsku logiku jer je zavisna varijabla označena s 0 za stabilno poslovanje i 1 za poslovne subjekte koji imaju nestabilno poslovanje, odnosno financijske poteškoće. Na temelju dobivenih vrijednosti sva tri modela mogu se prikazati na sljedeći način:

$$P_g = \frac{e^{0.453 - 4.100 \cdot L_2 + 0.011 \cdot A_5 - 0.033 \cdot P_9}}{(1 + e^{0.453 - 4.100 \cdot L_2 + 0.011 \cdot A_5 - 0.033 \cdot P_9})} \quad (2)$$

$$P_p = \frac{e^{0.404 - 4.2430 \cdot L_2 + 0.014 \cdot A_5}}{(1 + e^{0.404 - 4.2430 \cdot L_2 + 0.014 \cdot A_5})} \quad (3)$$

$$P_t = \frac{e^{-0.127 - 4.007 \cdot L_2 + 0.02 \cdot A_5}}{(1 + e^{-0.127 - 4.007 \cdot L_2 + 0.02 \cdot A_5})} \quad (4)$$

Modeli su u sljedećem koraku procijenjeni Omnibus testom.

Tablica 6. Omnibus test.

	Građevinska djelatnost			Prerađivačka djelatnost			Trgovinska djelatnost	
	Hi-kvadrat	df		Hi-kvadrat	df		Hi-kvadrat	df
Step	-0.275 ^a	1		19.771***	1		36.726	1
Block	97.580***	3		74.768***	2		88.185	2
Model	97.580***	3		74.768***	2		88.185	2

*** $p < 0.01$

^a vrijednost odabranog modela u petom koraku jest negativna jer je model u petom koraku iskazao nižu vrijednost u odnosu na model u četvrtom koraku tijekom *stepwise* procedure. Četvrti korak nije prihvaćen zato što je uključio nesignifikantnu prediktorsku varijablu. Modeli za prerađivačku djelatnosti i trgovinu generirani su iz dva koraka.

Izvor: izrada autora

Na temelju dobivenih vrijednosti u Tablici 6. može se zaključiti da dobiveni modeli za sve tri djelatnosti predstavljaju poboljšanje u odnosu na „baseline“ model nakon dodavanja prediktorskih varijabli. U sljedećem koraku procijenjene su pseudo R^2 vrijednosti dobivenih modela.

Tablica 7. Mjere prikladnosti modela.

	Građevinska djelatnost	Prerađivačka djelatnost	Trgovinska djelatnost
-2 Log likelihood	175.659 ^a	196.635 ^a	188.979 ^b
Cox & Snell R square	0.380	0.307	0.344
Nagelkerke R square	0.515	0.417	0.469

^a procjena je završena na iteraciji 8 zbog promjene procjene parametara za < 0.001.

^b procjena je završena na iteraciji 6 zbog promjene procjene parametara za < 0.001.

Izvor: izrada autora

Pseudo R² vrijednost pokazatelja objašnjava kolika je količina varijacija objašnjena modelom, s obzirom na to da su vrijednosti aproksimirane, što se može utvrditi na temelju razlike u vrijednosti između Cox & Snell R² i Nagelkerke R² ovaj se pokazatelj tumači s određenom dozom opreza. Na temelju dobivenih vrijednosti može se zaključiti da su modeli zadovoljavajući. Sljedeći prikazani test jest Hosmer Lemeshow test čije su dobivene vrijednosti prikazane u nastavku.

Tablica 8. Hosmer i Lemeshow test.

	Građevinska djelatnost	Prerađivačka djelatnost	Trgovinska djelatnost
Hi-kvadrat	13.861	12.961	14.097
df	8	8	8
Sig.	0.085	0.113	0.079

Izvor: izrada autora

Dobiveni rezultati za sve tri djelatnosti ukazuju na dobru prilagodbu modela podacima, čime se sva tri modela smatraju adekvatnima. Kako bi se utvrdila prediktivna sposobnost svakog od navedenih modela, u nastavku su prikazane klasifikacijske tablice 9., 10. i 11. za svaku od spomenutih djelatnosti.

Tablica 9. Klasifikacijska tablica građevinske djelatnosti.

Promatrano	T-1			T-2			T-3			T-4			T-5		
	0	1	%	0	1	%	0	1	%	0	1	%	0	1	%
0 – stabilni	108	16	87.1	106	18	85.5	107	17	86.3	122	1	99.2	121	0	100.0
1 – nestabilni	20	60	75.0	27	48	64.0	30	36	54.5	39	14	26.4	16	7	30.4
Sveukupno			82.4			77.4			75.3			77.3			88.9

Izvor: izrada autora

Rezultati Klasifikacijske tablice 9. za građevinsku djelatnost prikazuju točnost predviđanja modela 1, 2, 3, 4 i 5 godina prije nastanka financijskih teškoća. Na temelju dobivenih rezultata može se zaključiti da je model najprecizniji godinu dana prije nastanka poslovnih teškoća (82.4 %), dok preciznost analizom prethodnih godina opada. U posljednjoj je godini preciznost nešto viša, ali ujedno je nužno naglasiti da je i uzorak korišten za predviđanje puno manji. Razlog tomu jest što su neki poslovni subjekti bili kasnije osnovani, te nisu na tržištu proveli 5 godina, već su nakon par godina poslovanja bili blokirani, dok za dio poslovnih subjekata podaci nisu bili dostupni, što je uzrokovalo oscilacije u promatranom uzorku, tako da je postotke točnosti važno promatrati zajedno s veličinom uzorka koja je bila aktualna u pojedinoj godini. Isto tako interesantno je primijetiti da je model kroz sve godine precizniji kod predviđanja stabilnih poslovnih subjekata u odnosu na financijski nestabilne. U nastavku je prikazana Klasifikacijska tablica 10. za poslovne subjekte unutar prerađivačke djelatnosti.

Tablica 10. Klasifikacijska tablica prerađivačke djelatnosti.

Promatrano	T-1			T-2			T-3			T-4			T-5		
	0	1	%	0	1	%	0	1	%	0	1	%	0	1	%
0 – stabilni	110	16	87.3	114	12	90.5	115	11	91.3	116	9	92.8	121	3	97.6
1 – nestabilni	28	50	64.1	22	49	69.0	24	43	64.2	31	22	41.5	27	5	15.6
Sveukupno			78.4			82.7			81.9			77.5			80.8

Izvor: izrada autora

Dobiveni rezultati sugeriraju da su nešto viši postotci predviđanja kod prerađivačke djelatnosti uočeni u drugoj i trećoj godini u odnosu na prvu, iako je veličina uzorka stabilnih subjekata ista, dok je uzorak nestabilnih poslovnih subjekata nešto niži. Ukupna točnost modela tijekom svih 5 godina kreće se u rasponu od 77.5 % – 82.7 %, što se ujedno smatra zadovoljavajućim rezultatom predviđanja.

Tablica 11. Klasifikacijska tablica trgovačke djelatnosti.

	T-1			T-2			T-3			T-4			T-5		
	0	1	%	0	1	%	0	1	%	0	1	%	0	1	%
0 – stabilni	120	10	92.3	123	7	94.6	120	7	94.5	124	3	97.6	121	1	99.2
1 – nestabilni	31	48	60.8	26	43	62.3	17	40	70.2	32	5	13.5	22	4	15.4
Sveukupno			80.4			83.4			87.0			78.7			84.5

Izvor: izrada autora

Rezultati na temelju modela predviđanja za trgovačku djelatnost (Tablica 11.) vrlo su slični u usporedbi s prethodne dvije djelatnosti. Može se uočiti da je jednako kao u prethodnom primjeru postotak ispravnog predviđanja nešto viši druge (80.4 %) i treće godine (87.0 %) u odnosu na prvu godinu, no i uzorak je nešto manji.

Na temelju dobivenih rezultata može se zaključiti da modeli imaju zadovoljavajuću razinu predviđanja za prve tri godine, dok je ona u četvrtoj i petoj godini značajno narušena, posebno kada se govori o predviđanju nestabilnih poslovnih subjekata, iako je sveukupni postotak zadovoljavajuće visine, što je rezultat visoke prediktivnosti stabilnih poslovnih subjekata. Nastavno na to, može se ujedno primijetiti da je kod građevinske djelatnosti postotak predviđanja nestabilnih subjekata u 4. godini 26.4 %, dok je u 5. godini 30.4 %. Kada se govori o prerađivačkoj djelatnosti tada je u 4. godini 41.5 %, dok je u 5. godini svega 15.6 %, dok je kod trgovačke djelatnosti ujedno i najslabiji, te iznosi u 4. godini 13.5 %, a u 5. godini 15.4 %. Nakon primjene logit metode na poslovnim subjektima triju različitih djelatnosti može se zaključiti da korištenje modela za predviđanje razdoblja dužeg od tri godine nije preporučljivo zato što preciznost značajno opada u četvrtoj i petoj godini.

4. ZAKLJUČAK

Predviđanje financijske nestabilnosti predmet je izučavanja akademske zajednice još od 30-ih godina 20. st. Iako je od samih početaka popularizacije teme prošlo nešto manje od stoljeća, navedena tema zadržala je sve do danas svoju relevantnost i aktualnost. Ono po čemu se dosadašnji radovi međusobno razlikuju jest način definiranja financijske (ne)stabilnosti. Tako su neki radovi determinirali financijski nestabilna poduzeća kao ona koja su otvorila stečaj (Bogdan *et al.*, 2019, 2021), Novak i Crnković (2007), te Zenzerović (2009) razlikuju dobre i loše poslovne subjekte prema financijskim pokazateljima, dok Šarlija i Jeger (2011) nestabilnim poslovnim subjektima smatraju one koji nisu unutar godine dana mogli podmiriti obvezu najmanje 90 dana.

U ovome istraživanju nestabilne su kompanije definirane kao one koje su u razdoblju 1. 1. 2022. – 16. 12. 2023. provele najmanje 60 dana u blokadi neovisno o tome je li blokada prekinuta ili još traje. Odabrani su poslovni subjekti unutar građevinske, trgovačke i prerađivačke djelatnosti jer je u sumi navedenih triju djelatnosti broj blokiranih kompanija iznosio 47.8 % svih blokiranih kompanija

u promatranom razdoblju. Svrha ovog istraživanja bila je procijeniti model za predviđanje financijskih poteškoća, jednako kao i detektirati ključne financijske indikatore koji bi mogli poslužiti u modelu kao signifikantne prediktorske varijable. Nakon provedenih testiranja uklonjene su pojedine prediktorske varijable za svaki od sektora radi izbjegavanja problema multikolinearnosti, nakon čega je provedena *stepwise* logistička regresija s opcijom odabira unaprijed. Na temelju navedene metodologije determinirani su modeli za svaku od odabranih djelatnosti. Financijski pokazatelji kao što su koeficijent vlastitog financiranja i dani plaćanja dobavljačima pokazali su se signifikantnima u svim trima modelima za svaku od djelatnosti, dok se pokazatelj EBITDA marža pokazao signifikantnim u građevinskoj djelatnosti. Nakon procjene pojedinačnih modela testirana je njihova točnost predviđanja 1, 2, 3, 4 i 5 godina prije blokade u poslovanju. Dobiveni rezultati sugeriraju da je u građevinskom sektoru mogućnost predviđanja na ukupnom uzorku u rasponu od 82.4 - 75.3 % za prve tri godine, dok se u četvrtoj i petoj godini stopa predviđanja nestabilnih poslovnih subjekata kreće u rasponu 26.4 - 30.4 %. Slični rezultati dobiveni su i u prerađivačkoj djelatnosti gdje se stopa predviđanja za prve tri godine kreće u rasponu 82.7 - 78.4 %, u četvrtoj godini predviđanje nestabilnih kompanija pada na 41.5 %, dok u petoj to iznosi svega 15.6 %. Model namijenjen trgovačkoj djelatnosti, prema Klasifikacijskoj tablici 11. također zadovoljava jer je ostvario u prve tri godine na temelju ukupnog uzorka točnost predviđanja u rasponu 87.0 - 80.4 %, te jednako kao u prethodna dva modela, postotak predviđanja nestabilnih kompanija naglo opada u 4. i 5. godini te iznosi svega 13.5 % i 15.4 %.

Na temelju navedenih rezultata, kao što je bilo i očekivano, može se zaključiti da navedene modele nije uputno koristiti za razdoblje duže od tri godine. Također, za ograničenje istraživanja vrijedno je napomenuti da bi veći uzorak poslovnih subjekata pružio veću statističku snagu istraživanja, a time i pouzdanije zaključke. Za buduća istraživanja preporučuje se korištenje naprednijih metoda u području strojnog učenja, odnosno umjetne inteligencije s ciljem unapređenja prediktivne točnosti prilikom analize dobivenih modela.

REFERENCE

1. Altman, E. I. (1968) Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, Vol. 23, No. 4, str. 589-609.
2. Altman, E. I. (1983) *Corporate Financial Distress A Complete Guide to Predicting, Avoiding, and Dealing with Bankruptcy*. Wiley Interscience, John Wiley and Sons: New York.

3. Altman, E. I. (2018) Applications of distress prediction models: What have we learned after 50 years from the Z-Score models? *International Journal of Financial Studies*, Vol. 6, No. 3, str. 1–15.
4. Altman, E. I., Danovi, A. i Falini, A. (2013) Z-Score Models' application to Italian companies subject to extraordinary administration. *Journal of Applied Finance*, Vol. 23, No. 1, str. 128–137.
5. Altman, E. I., Haldeman, R. G. i Narayanan, P. (1977) ZETA Analysis: A New Model to Identify Bankruptcy Risk of Corporations. *Journal of Banking and Finance*, Vol. 1, No. 1, str. 29–54.
6. Altman, E. I., Hartzell, J. i Peck, M. (1995). *Emerging Markets Corporate Bonds: A Scoring System*. New York: Salomon Brothers.
7. Altman, E. I., Iwanicz-Drozdzowska, M., Laitinen, E. K. i Suvas, A. (2014) Distressed firm and bankruptcy prediction in an international context: A review and empirical analysis of Altman's Z-score model. *SSRN Electronic Journal*. Doi: 10.2139/ssrn.2536340.
8. Bernhardsen, E. (2001). A model of bankruptcy prediction (No. 2001/10). Working Paper.
9. Blum, M. (1974) Failing company discriminant analysis. *Journal of Accounting Research*, Vol. 12, No. 1, str. 1–25.
10. Bogdan, S. (2021). Predviđanje stečaja u restoranskoj industriji Hrvatske. *Ekonomskamisao i praksa*, Vol. 30, No. 1, str. 99–119.
11. Bogdan, S., Bareša, S. i Hadina, V. (2019). Testiranje primjenjivosti Altmanovog Z-score modela za predviđanje stečaja u Republici Hrvatskoj. *Notitia-časopis za ekonomske, poslovne i društvene teme*, Vol. 5, No. 1, str. 31–46.
12. Bogdan, S., Šikić, L. i Bareša, S. (2021). Predicting Bankruptcy Based On The Full Population Of Croatian Companies. *Ekonomski pregled*, Vol. 72, No. 5, str. 643–669.
13. Dimitras, A. I., Slowinski, R., Susmaga, R. i Zopounidis, C. (1999). Business failure prediction using rough sets. *European Journal of operational research*, Vol. 114, No. 2, str. 263–280.
14. Edmister, R. O. (1972) An empirical test of financial ratio analysis for small business failure prediction. *Journal of Financial and Quantitative analysis*, Vol. 7, No. 2, str. 1477–1493.
15. Ekonomski institut Zagreb. (2023). Sektorske analize, br. 103. https://www.eizg.hr/userdocsimages/publikacije/serijske-publikacije/sektorske-analize/SA_Trgovina_2023.pdf (pristupljeno 26. prosinca 2023.)
16. Etheridge, H. L. i Sriram, R. S. (1997). A comparison of the relative costs of financial distress models: artificial neural networks, logit and multivariate discriminant analysis. *Intelligent Systems in Accounting, Finance & Management*, Vol. 6, No. 3, str. 235–248.
17. Fitzpatrick, P. (1932). A comparison of the ratios of successful industrial enterprises with those of failed companies. *The Accountants Publishing Company*.

18. Ježovita, A. (2015). Designing The Model For Evaluating Financial Quality Of Business Operations-Evidence From Croatia. *Management: Journal of Contemporary Management Issues*, Vol. 20, No. 1, str. 101.
19. Kovacova, M. i Kliestik, T. (2017). Logit and Probit application for the prediction of bankruptcy in Slovak companies. *Equilibrium. Quarterly Journal of Economics and Economic Policy*, Vol. 12, No. 4, str. 775-791.
20. Kristanti, F. T. i Dhaniswara, V. (2023). The accuracy of artificial neural networks and logit models in predicting the companies' financial distress. *Journal of technology management & innovation*, Vol. 18, No. 3, str. 42-50.
21. Muparuri, L. i Gumbo, V. (2022). On logit and artificial neural networks in corporate distress modelling for Zimbabwe listed corporates. *Sustainability Analytics and Modeling*, Vol. 2, 100006.
22. Novak, B. i Crnković, I. (2007). Klasifikacija dužnika banke prema razini poslovnih problema na osnovi podataka iz osnovnih financijskih izvješća. *Ekonomski pregled*, Vol. 58, No. 1-2, str. 41-71.
23. Ohlson, J. A. (1980) Financial ratios and the probabilistic prediction of bankruptcy. *Journal of accounting research*, Vol. 18, No.1, str. 109-131.
24. Ramser, J. i Foster, L. (1931). A demonstration of ratio analysis. Bulletin No. 40, Urbana, Ill. University of Illinois, Bureau of Business Research.
25. Sajter, D. (2008). Ekonomski aspekti stečaja i restrukturiranja u stečaju. Doctoral dissertation, Ekonomski fakultet u Osijeku.
26. Sajter, D. (2009). Pregled određenih metoda i istraživanja poslovnih poteskoca uz predviđanje stečaja. *Ekonomika misao i praksa*, Vol. 18, No. 2, str. 429.
27. Shi, Y. i Li, X. (2019). An overview of bankruptcy prediction models for corporate firms: A systematic literature review. *Intangible Capital*, Vol. 15, No. 2, str. 114-127.
28. Stečajni zakon, <https://www.zakon.hr/z/160/Ste%C4%8Dajni-zakon> (pristupljeno 10. prosinca 2023.)
29. Šarlija, N. i Jeger, M. (2011). Comparing financial distress prediction models before and during recession. *Croatian Operational Research Review*, Vol. 2, No. 1, str. 133-142.
30. Šošić, I. (2006). Primjenjena statistika. Zagreb: Školska knjiga.
31. Wilcox, J. W. (1973) A prediction of business failure using accounting data. *Journal of Accounting Research*, Vol. 11, str. 163-179.
32. Winakor, A. i Smith, R. (1935). Changes in the financial structure of unsuccessful industrial corporations. Bulletin No. 51, 1935. University of Illinois, Bureau of Business Research: Urbana, Illinois.
33. Zavgren, C. V. (1985). Assessing the vulnerability to failure of American industrial firms: a logistic analysis. *Journal of Business Finance & Accounting*, Vol. 12, No. 1, str. 19-45.
34. Zenzerović, R. (2009). Business' Financial Problems Prediction-Croatian Experience. *Economic research-Ekonomika istraživanja*, Vol. 22, No. 4, str. 1-15.
35. Zmijewski, M. E. (1984). Methodological issues related to the estimation of financial distress prediction models. *Journal of Accounting research*, str. 59-82.

PRILOZI

Prilog 1. Korelacijska matrica nezavisnih varijabli u građevinskoj djelatnosti

	Q1	Q2	Q3	S1	L1	L2	L3	L4	L5	L6	A1	A2	A3	A4	A5	P1	P2	P3	P4	P5	P6	P7	P8	P9
Q1	1.0																							
Q2	0.8	1.0																						
Q3	0.6	0.7	1.0																					
S1	-0.1	-0.1	-0.1	1.0																				
L1	0.0	-0.1	-0.1	0.0	1.0																			
L2	0.5	0.5	0.4	-0.2	-0.1	1.0																		
L3	-0.1	-0.1	-0.1	0.4	0.0	-0.4	1.0																	
L4	0.0	0.0	0.0	0.0	0.1	-0.1	0.1	1.0																
L5	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.8	1.0															
L6	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.8	1.0	1.0														
A1	-0.1	0.0	-0.1	-0.1	0.9	-0.1	0.0	0.1	0.0	0.0	1.0													
A2	-0.1	-0.1	-0.1	0.1	0.5	-0.1	0.0	0.1	0.0	0.0	0.6	1.0												
A3	-0.1	-0.1	0.0	-0.1	0.0	-0.2	0.0	0.0	0.0	0.0	-0.1	-0.1	1.0											
A4	-0.1	0.0	-0.1	-0.1	0.0	-0.2	0.0	0.0	0.0	0.0	-0.1	-0.2	0.5	1.0										
A5	-0.2	-0.2	-0.1	0.0	0.1	-0.3	0.1	0.0	-0.1	-0.1	-0.1	-0.1	0.6	0.4	1.0									
P1	0.3	0.2	0.2	0.0	0.0	0.3	0.0	0.0	0.0	0.0	0.0	0.0	-0.4	-0.3	-0.2	1.0								
P2	0.2	0.1	0.1	0.1	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.3	-0.3	-0.2	-0.1	0.7	1.0							
P3	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.1	0.1	-0.8	-0.1	-0.7	0.3	0.3	1.0						
P4	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.1	0.1	-0.8	-0.1	-0.7	0.3	0.3	1.0	1.0					
P5	0.2	0.2	0.2	-0.1	-0.3	0.3	-0.1	-0.1	0.0	0.0	-0.2	-0.1	-0.1	-0.2	-0.2	0.6	0.4	0.1	0.1	1.0				
P6	0.2	0.2	0.2	0.0	-0.3	0.3	-0.1	-0.1	0.0	0.0	-0.2	-0.1	-0.1	-0.2	-0.1	0.5	0.4	0.1	0.1	1.0	1.0			
P7	0.0	0.0	0.0	0.0	-0.1	-0.1	0.3	0.2	0.2	0.2	0.1	-0.1	-0.1	-0.1	0.0	0.4	0.3	0.1	0.1	0.4	0.4	1.0		
P8	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.1	0.1	-0.8	-0.1	-0.7	0.3	0.3	1.0	1.0	0.1	0.1	0.1	1.0	
P9	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.1	0.1	-0.8	-0.1	-0.7	0.3	0.3	1.0	1.0	0.1	0.1	0.1	1.0	1.0

Izvor: izrada autora

Prilog 2. Korelacijska matrica nezavisnih varijabli u prerađivačkoj djelatnosti

	Q1	Q2	Q3	S1	L1	L2	L3	L4	L5	L6	A1	A2	A3	A4	A5	P1	P2	P3	P4	P5	P6	P7	P8	P9
Q1	1.0																							
Q2	0.9	1.0																						
Q3	0.8	1.0	1.0																					
S1	-0.1	-0.2	-0.2	1.0																				
L1	-0.1	-0.1	-0.2	0.0	1.0																			
L2	0.3	0.5	0.5	-0.3	-0.3	1.0																		
L3	-0.1	-0.1	-0.1	0.3	0.0	-0.2	1.0																	
L4	0.0	-0.1	-0.1	0.0	0.7	-0.3	0.6	1.0																
L5	0.0	0.1	0.1	-0.2	-0.1	0.1	0.0	0.0	1.0															
L6	0.0	0.0	0.0	-0.2	0.0	0.1	0.0	0.0	0.9	1.0														
A1	0.0	-0.1	-0.1	-0.1	0.9	-0.2	0.0	0.6	0.0	0.0	1.0													
A2	-0.1	-0.1	-0.1	0.0	0.9	-0.2	0.0	0.6	0.0	0.0	1.0	1.0												
A3	0.0	0.0	0.0	0.2	0.0	-0.1	0.0	0.0	0.0	0.0	-0.1	-0.1	1.0											
A4	0.0	0.0	0.0	0.2	0.0	-0.1	0.2	0.1	0.0	0.0	-0.1	-0.1	0.3	1.0										
A5	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.4	0.2	0.0	0.0	0.0	0.0	1.0									
P1	0.0	0.1	0.0	-0.1	0.0	0.1	0.0	0.0	0.4	0.2	0.0	0.0	0.0	0.0	1.0	1.0								
P2	0.0	0.1	0.0	-0.1	0.0	0.1	0.0	0.0	0.4	0.2	0.0	0.0	0.0	0.0	1.0	1.0	1.0							
P3	0.1	0.2	0.2	-0.2	-0.1	0.2	0.0	0.0	0.1	0.1	0.0	0.0	-0.9	-0.2	0.1	0.1	0.1	1.0						
P4	0.1	0.1	0.1	-0.2	-0.1	0.2	0.0	0.0	0.1	0.1	0.0	0.0	-0.9	-0.2	0.1	0.1	0.1	1.0	1.0					
P5	0.1	0.1	0.1	0.0	-1.0	0.3	0.0	-0.6	0.1	0.1	-0.9	-0.9	0.0	0.0	0.1	0.1	0.1	0.2	0.2	1.0				
P6	0.1	0.1	0.1	0.0	-1.0	0.3	0.0	-0.6	0.1	0.1	-0.9	-0.9	0.0	0.0	0.1	0.1	0.1	0.2	0.1	1.0	1.0			
P7	0.0	0.0	0.0	0.3	0.0	-0.1	0.2	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.1	0.1	0.1	1.0		
P8	0.1	0.2	0.2	-0.1	-0.1	0.3	0.0	0.0	0.1	0.1	0.0	0.0	-0.9	-0.2	0.2	0.2	0.2	1.0	1.0	0.2	0.2	0.1	1.0	
P9	0.2	0.2	0.2	-0.1	-0.1	0.3	0.0	0.0	0.1	0.1	0.0	0.0	-0.9	-0.2	0.2	0.2	0.2	1.0	1.0	0.2	0.2	0.1	1.0	1.0

Izvor: izrada autora

Prilog 3. Korelacijska matrica nezavisnih varijabli u trgovačkoj djelatnosti

	Q1	Q2	Q3	S1	L1	L2	L3	L4	L5	L6	A1	A2	A3	A4	A5	P1	P2	P3	P4	P5	P6	P7	P8	P9
Q1	1.0																							
Q2	0.5	1.0																						
Q3	0.5	1.0	1.0																					
S1	0.0	0.0	-0.1	1.0																				
L1	0.0	0.0	-0.1	0.0	1.0																			
L2	0.4	0.3	0.4	-0.1	-0.1	1.0																		
L3	0.0	-0.1	-0.1	0.0	0.0	-0.2	1.0																	
L4	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	1.0																
L5	0.0	0.1	0.1	-0.1	0.0	0.2	0.0	0.0	1.0															
L6	0.0	0.1	0.1	-0.1	0.0	0.2	0.0	0.0	1.0	1.0														
A1	0.0	0.0	0.0	-0.1	0.0	-0.1	-0.1	0.2	0.0	0.0	1.0													
A2	0.0	0.0	0.0	0.0	0.0	-0.1	0.5	0.0	0.0	0.0	0.1	1.0												
A3	-0.1	0.1	0.0	0.0	0.0	-0.1	0.1	0.0	0.0	0.0	-0.2	-0.1	1.0											
A4	-0.1	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	-0.2	-0.1	0.9	1.0										
A5	-0.1	-0.1	-0.1	0.1	0.0	-0.2	0.2	0.0	0.0	0.0	-0.3	0.0	0.7	0.6	1.0									
P1	0.9	0.4	0.4	0.0	0.0	0.2	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	1.0								
P2	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.1	-0.1	0.0	0.0	0.4	0.0	0.0	1.0							
P3	0.3	0.2	0.2	0.0	-0.4	0.3	0.0	0.0	0.2	0.2	0.0	0.0	0.0	-0.3	0.0	0.3	-0.6	1.0						
P4	0.3	0.2	0.2	0.0	-0.4	0.3	0.0	0.0	0.1	0.1	0.0	0.0	0.0	-0.3	0.0	0.3	-0.6	1.0	1.0					
P5	0.3	0.2	0.2	0.0	-0.5	0.5	0.0	-0.2	0.3	0.2	0.0	0.0	0.0	-0.1	-0.1	0.2	-0.1	0.6	0.6	1.0				
P6	0.3	0.2	0.2	0.0	-0.5	0.4	0.0	-0.3	0.2	0.2	0.0	0.0	0.0	-0.1	-0.1	0.2	-0.1	0.6	0.6	1.0	1.0			
P7	0.1	0.1	0.1	-0.1	-0.1	-0.1	0.1	0.0	0.1	0.1	0.2	0.2	0.1	0.0	0.1	0.1	0.0	0.3	0.3	0.3	0.3	1.0		
P8	0.3	0.2	0.2	0.0	0.0	0.2	0.0	-0.1	0.3	0.3	-0.1	0.0	0.0	0.1	-0.1	0.3	0.6	0.2	0.2	0.4	0.3	0.2	1.0	
P9	0.4	0.3	0.3	0.0	-0.1	0.3	-0.1	-0.1	0.2	0.2	-0.2	-0.1	0.0	0.2	-0.1	0.5	0.6	0.1	0.1	0.4	0.4	0.2	0.9	1.0

Izvor: izrada autora

Prilog 4. Testiranje kolinearnosti

Građevinska djelatnosti			Prerađivačka industrija			Trgovinska djelatnost		
Varijabla	Tolerancija	VIF	Varijabla	Tolerancija	VIF	Varijabla	Tolerancija	VIF
Q1	0.384	2.606	Q1	0.321	3.115	Q1	0.603	1.659
Q3	0.391	2.556	Q3	0.252	3.975	Q2	0.664	1.506
S1	0.883	1.132	S1	0.657	1.523	S1	0.947	1.055
L1	0.528	1.895	L2	0.592	1.690	L1	0.651	1.536
L2	0.500	2.001	L3	0.375	2.666	L2	0.527	1.896
L3	0.635	1.574	L4	0.276	3.627	L3	0.685	1.460
L5	0.933	1.071	L5	0.817	1.224	L4	0.858	1.166
A2	0.587	1.704	A2	0.422	2.367	L5	0.846	1.182
A3	0.301	3.325	A3	0.901	1.110	A1	0.762	1.312
A5	0.409	2.447	A4	0.873	1.145	A2	0.710	1.409
P2	0.365	2.740	A5	0.864	1.157	A3	0.440	2.275
P5	0.404	2.477	P7	0.858	1.166	A5	0.381	2.622
P7	0.660	1.515				P2	0.540	1.851
P9	0.265	3.770				P5	0.358	2.793
						P7	0.640	1.563
						P8	0.423	2.365

Izvor: izrada autora

PREDICTING THE FINANCIAL INSTABILITY OF SELECTED COMPANIES IN THE POST-PANDEMIC PERIOD

Associate Professor Siniša Bogdan, PhD

University of Rijeka, Faculty of Tourism and Hospitality Management

sinisab@fthm.hr

ABSTRACT

The purpose of this paper is to evaluate models for predicting the financial instability of business entities by analysing different sectors in the Republic of Croatia, particularly within the post-pandemic period. The focus is on the construction, manufacturing, and retail sectors, aiming to determine significant financial predictors for each of these sectors. In this study, financial instability is defined as the freezing of accounts for a period of 60 days or longer. The observed period refers to the post-pandemic timeframe: January 1, 2022, to December 16, 2023. Using logistic regression, specifically the forward stepwise LR procedure, predictive models were developed for all three sectors, and the accuracy of these predictions was tested for five years before the account freeze. The results show that the coefficient of self-financing and payment days to suppliers are present as independent variables in all three models, while the EBITDA margin is only present in the model predicting financial difficulties in the construction sector. All three models showed a prediction accuracy ranging from 77.3% to 87.0% within the first three years, which is considered satisfactory. The results indicate that the predictive accuracy of the models for unstable companies decreases exponentially after the third year. Therefore, it is not recommended to use the model for longer than three years.

Key words: blockade, bankruptcy, financial difficulties, logit

JEL classification: G33, G34

UTJECAJ BOLESTI COVID-19 NA *PRIVATE EQUITY* TRŽIŠTE U CEE REGIJI¹

Anamarija Mlikotić, univ. bacc. oec.

Sveučilište u Splitu, Ekonomski fakultet

e-mail: amliko01@live.efst.hr

izv. prof. dr. sc. Marija Šimić Šarić

Sveučilište u Splitu, Ekonomski fakultet

e-mail: msimic@efst.hr

SAŽETAK

Private equity (PE) i venture capital (VC) ulaganja značajna su za gospodarstva zemalja diljem svijeta pa tako i za gospodarstva zemalja Srednjoistočne Europe (CEE). PE/VC tržišta, kao ni druga tržišta, nisu imuna na različite krize koje se javljaju tijekom vremena pa tako ni na krizu izazvanu pandemijom bolesti COVID-19. Problem rada vezan je uz utjecaj krize uzrokovane pandemijom bolesti COVID-19 na PE tržište CEE zemalja, što nije istraženo. Svrha istraživanja jest utvrditi utjecaj same krize na pojedine segmente PE tržišta. Na temelju provedenog istraživanja može se zaključiti kako je kriza utjecala na iznos prikupljenih sredstava i veličinu ulaganja, način upravljanja portfeljem, ostvarene izlaze, strukturu ulaganja te sektore ulaganja. Naime, prikupljena sredstva i veličina ulaganja u 2020. godini smanjila su se u odnosu na vrijeme prije krize, tj. 2019. godinu. Fokus fondova bio je na postojećem portfelju, a manje na novim ulaganjima. Izlazi iz portfelj poduzeća su odgođeni, udio venture capital ulaganja je porastao, dok su se buyout ulaganja smanjila. Na kraju je potrebno istaknuti kako su sve promjene do kojih je došlo bile kratkoročnog karaktera. Naime, PE tržište već se u 2021. godini oporavilo.

Ključne riječi: COVID-19, *private equity*, CEE regija, *venture capital*

JEL klasifikacija: G00, G20, G24

¹ Rad je rezultat znanstvene nadogradnje obranjenog završnog rada kolegice Mlikotić pod mentorstvom izv. prof. dr. sc. Marije Šimić Šarić.

1. UVOD

Alternativni izvori financiranja, kao što su *private equity* (PE) i *venture capital* (VC), uz novčanu potporu poduzećima, pružaju i mnogobrojne druge benefite, kao što su menadžersko znanje, strateški i organizacijski savjeti te informacije, a sve s ciljem osiguranja njihova rasta i razvoja (Caselli i Negri, 2018; Šimić Šarić, 2019). Za poduzetnike koji imaju poteškoća u pronalasku adekvatnih izvora financiranja, kako vlastitog tako i tuđeg, tržište *private equityja* i *venture capitala* (PE/VC) ključno je zbog realizacije poslovnih aktivnosti, kao i za rješavanje financijskih problema. Uz financiranje poduzeća, PE/VC tržišta podupiru inovativnost i razvoj novih tehnologija doprinoseći rastu i razvoju cjelokupnog gospodarstva (Cumming i Johan, 2014).

Iako su svoje početke PE i VC dominantno pronašli u Sjedinjenim Američkim Državama i Ujedinjenom Kraljevstvu (Bottazzi, 2010), oni sve veći utjecaj imaju na međunarodnom tržištu, pa tako i u Srednjoistočnoj Europi. Prije tridesetak godina velik je broj država napravio tranziciju s planskog na tržišno gospodarstvo u regiji Srednjoistočne Europe omogućujući i razvoj PE/VC tržišta, investicijskih mogućnosti i strategija poslovanja (Invest Europe, 2021a). Tijekom tog razvoja, PE i VC imali su i uspone i padove, često sukladno događajima i krizama na globalnoj razini, a posljednji takav događaj bila je pandemija bolesti COVID-19. Ona predstavlja razdoblje nesigurnosti i neizvjesnosti u kojem je narušena svakodnevica na osobnoj i poslovnoj razini svih ljudi na svijetu. Predmet ovog istraživanja jest analiza utjecaja pandemije bolesti COVID-19 na PE u regiji Srednjoistočne Europe.

Rad je organiziran na sljedeći način. Nakon uvoda, dan je pregled razvoja PE/VC tržišta u zemljama Srednjoistočne Europe. Zatim je u trećem poglavlju dan prikaz analize prikupljanja kapitala i ulaganja u razdoblju od 2013. do 2019. godine. Slijedi četvrto poglavlje s teorijskim prikazom utjecaja krize uzrokovane pandemijom bolesti COVID-19 na PE tržište. Analiza PE-a u regiji CEE u razdoblju od 2020 do 2021. dana je u petom poglavlju, nakon kojeg je dan zaključak.

2. RAZVOJ PE-A I VC-A U ZEMLJAMA SREDNJOISTOČNE EUROPE

Regiju Srednjoistočne Europe (CEE) čini sljedećih 17 država: Bosna i Hercegovina, Bugarska, Crna Gora, Češka, Estonija, Hrvatska, Latvija, Litva, Moldavija, Mađarska, Poljska, Rumunjska, Sjeverna Makedonija, Slovačka, Slovenija, Srbi-

ja i Ukrajina. Od navedenih 17 država, jedanaest je članica Europske unije. Većinom je riječ o državama koje su 90-ih godina 20. stoljeća napravile tranziciju iz planskog u tržišno gospodarstvo i ta ih činjenica prelaska iz socijalističkih i komunističkih u kapitalističke države objedinjuje u jednu zajedničku regiju (Dallago, 2003). Populacija svih država zajedno u 2022. godini iznosila je otprilike 151,5 milijun, a ukupni BDP iznosio je 2,1 trilijuna eura, što je četiri puta više u odnosu na 1995. godinu (Invest Europe, 2023). Regija CEE danas igra važnu ulogu u cjelokupnoj europskoj politici i okruženju, a njihove industrijske i trgovinske mogućnosti čine ih dijelom europske ekonomije proizvoda i usluga.

Diaconu (2017) i Karsai (2009) razvoj *private equity* tržišta u zemljama CEE-a podijelili su u četiri faze. Prva faza započela je u tranzicijskom razdoblju i trajala je do sredine 90-ih godina 20. stoljeća. Navedeno razdoblje obilježila je privatizacija velikog broj poduzeća. S jedne strane, u nekim slučajevima poduzeća su bila prodana stranim investitorima s ciljem ujednačavanja svojih strategija vodstva, menadžmenta te stvaranja profitabilnosti globalnim standardima, što se, međutim, nije uvijek poštovalo. S druge strane, poduzeća su se davala menadžerima i zaposlenicima putem brojnih privatizacijskih programa. Ista su većinom bila u lošoj financijskoj situaciji s velikim dugovima, lošom i zastarjelom tehnologijom koja je dodatno usporavala proizvodnju. Rješenja za neke od tih problema pružale su specijalizirane *venture capital* firme. Dominantni su bili *country* fondovi, a tipična veličina kapitala kojom su fondovi raspolagali iznosila je oko 50 milijuna dolara. Drugu fazu, koja je završila do kraja 90-ih godina 20. stoljeća, obilježili su regionalni fondovi, čija je vrijednost bila između 100 i 200 milijuna dolara. U fokusu financiranja bila su poduzeća koja su bila u fazi ekspanzije. Tada je započelo učvršćivanje *private equity* tržišta u CEE-u. Slomom *dot-com* balona završila je treća faza, a njezina glavna karakteristika bio je brz razvoj i ekspanzija. Regionalni fondovi još su uvijek bili dominantni, a iznos kapitala kojom su raspolagali dosegli su između 250 i 300 milijuna dolara. Investitori su se fokusirali na ulaganja u području tehnologije, informatike te medija, a ulagalo se i u poduzeća u ranim fazama te fazama ekspanzije. Posljednja razvojna faza trajala je od 2001. do 2006. godine. U navedenom razdoblju tržište *private equityja* bolje je organizirano, racionalizirano i uspostavljeni su čvršći temelji. Rastom i razvojem PE/VC tržišta mijenjala su se područja i strategije investiranja te su se razvile brojne nove investicijske prilike (Invest Europe, 2021a).

Unatoč tridesetogodišnjem razvoju, PE/VC tržište CEE-a isto je slabije razvijeno u odnosu na PE/VC tržišta zapadne Europe i Sjeverne Amerike (Avots i sur., 2013; Milenković *et al.*, 2020). Međutim, CEE regija sve je atraktivnija

(Ljumović *et al.*, 2020). Udio ulaganja u rizični kapital u BDP-u regije znatno je niži od ostatka Europe, ali s vremenom razlika se počela značajno smanjivati (Karsai, 2009). Prema Diaconu (2017), PE/VC industrija u regiji CEE-a nije dosegla svoj maksimalni potencijal te još uvijek ima prostora za daljnji razvoj. Naime, ključni razlozi nižih ulaganja u fondove rizičnog kapitala vezani su uz brojna ograničenja koja su specifična za ovu regiju, kao što su: manjak lokalnih investitora, strani investitori ovo područje doživljavaju kao visokorizično, nedostatak iskusnog i stručnog menadžmenta u poduzećima u koje se ulaže te nedovoljno financiranje zajmom za transakcije s privatnim kapitalom. Nadalje, problem također stvaraju spor zakonodavni i regulatorni proces, neiskusna birokracija, nedostatak tržišnih prilika, prepreke pri otvaranju poduzeća i loš stečajni okvir. Prethodno istaknuto dodatno sprečava domaći kapital pri ulaganju u *private equity* fondove. Također, kao jedan od problema vezanih uz CEE regiju Karsai (2009) ističe nedostatak raspoloživih kreditnih linija, vrlo mali broj financiranih poduzeća u ranim razvojnim fazama zbog visokih transakcijskih troškova, nedostatak dobrih projekata te nedovoljnu podršku vlade pri ulaganju u ranim fazama.

3. ANALIZA PE-A U RAZDOBLJU OD 2013. DO 2019. GODINE


Podaci koji su korišteni u analizi preuzeti su iz izvješća asocijacije *Invest Europe*, koja je prije bila poznata kao *European Private Equity and Venture Capital Association*. Izvještaji se rade na temelju podataka prikupljenih u sklopu baze *European Data Cooperative* (EDC). Baza podataka kontinuirano se nadopunjava i nadograđuje u svrhu osiguranja ažurnosti i točnosti podataka te zbog toga može doći do razlike u podacima između narednih i prethodnih godina. Stoga su u radu korišteni posljednji ažurirani podaci za pojedina razdoblja. Podaci iz izvješća ručno su upisani u *excel* datoteku te su prikazani grafički i tablično.

3.1. PRIKUPLJANJE SREDSTAVA U ZEMLJAMA CEE-A

PE/VC fondovi sredstva za ulaganje u fondove prikupljaju iz različitih izvora, kao što su vladine agencije, mirovinski fondovi, bogati pojedinci, osiguravajuća društva, fondovi fondova, zaklade i drugi izvori (Šimić Šarić, 2019). Na Grafikonu 1. vidljivo je da su se u CEE regiji, u promatranom razdoblju od 2013. do 2019. godine, kao značajni izvori istaknule vladine agencije te fondovi

fondova, s iznimkom u 2015. godini kada fondovi fondova nisu imali nikakav doprinos. Ulaganja od strane vladinih organizacija u promatranom razdoblju kreću se od 24 do 43 %, a fondova fondova od 0 do 24 %. Osim njih, za prikupljanje sredstva u pojedinim godinama bili su važni korporativni investitori (2013. – 8 %; 2019. – 18 %), državni investicijski fondovi (2014. – 16 %; 2018. – 11 %), bogati pojedinci (2018. – 9 %; 2015. – 17 %; 2019. – 13 %), mirovinski fondovi (2016. – 16 %, 2014. – 11 %), banke (2019. – 11 %, 2018. – 9 %) te akademske institucije i zajednice (2017. – 8 %, 2016. – 14 %).

Grafikon 1. Izvori prikupljenih sredstava u regiji CEE-a u razdoblju od 2013. do 2019. godine




Izvor: izrada autorica prema *Invest Europe Central and Eastern Europe Private Equity Statistics* (2015, 2016, 2017, 2018, 2019, 2021, 2022) i *EVCA Special Paper, Central and Eastern Statistics* (2013, 2014)

Ukupno prikupljena sredstava za ulaganje u *private equity* fondove prešla su iznos od 9 milijardi eura u razdoblju od 2013. do 2019. godine. Najveći dosegnut iznos od 2,648 milijardi eura ostvaren je u 2018., dok je najmanji ostvareni iznos u 2015. godini, i to 389 milijuna eura (Grafikon 2.). U 2019. godini ukupni iznos prikupljenog kapitala bio je 1,568 milijardi eura, što je blizu prethodnog petogodišnjeg prosjeka, ali je došlo do snažnog pada od 48 % u odnosu na prethodnu, 2018. godinu, kada je ukupno prikupljeno 2,648 milijardi eura. U ostatku Europe iznos prikupljenih sredstava povećao se za 6 % te dosegnoo iznos od 106 milijardi eura. Iznos prikupljenih sredstava u CEE regiji iznosio je samo 1,3 % ukupno prikupljenih sredstava u 2019. godini. S druge strane, rast prikupljenih sredstava vidljiv je u 2014., 2016., 2017. i 2018. godini. Najveći rast u odnosu na prethodno razdoblje ostvaren je u 2014. godini, kada se količina prikupljenih sredstava utrostručila. Značajan iznos prikupljenih sredstava ostvaren je izvan Europe. Posebno se ističe doprinos kineskih javnih fondova,


čijim je investitorima to bila prva razmjerno velika investicija u *private equity* fondove u regiji. U 2016. godini rast je bio sukladan s pozitivnim trendovima u ostatku Europe, a u 2017. godini može se pripisati povećanoj aktivnosti na tržištu Srednjoistočne Europe.

Grafikon 2. Prikupljena sredstva u regiji CEE-a u razdoblju od 2013. do 2019. godine (u milijunima eura)



Izvor: izrada autorica prema *Invest Europe 2022 Central and Eastern Europe Private Equity Statistics*

Grafikon 3. Izvori prikupljenih sredstava s obzirom na geografsko podrijetlo u regiji CEE-a u razdoblju od 2013. do 2019. godine




Izvor: izrada autorica prema *Invest Europe Central and Eastern Europe Private Equity Statistics* (2015, 2016, 2017, 2018, 2019, 2021, 2022) i *EVCA Special Paper, Central and Eastern Statistics* 2013, 2014)

Grafikon 3. daje prikaz izvora prikupljenih sredstava s obzirom na geografsko podrijetlo. Glavni izvori prikupljenih sredstava su od investitora unutar Europe i regije CEE-a, osim u 2014. i 2018. godini, kada su dominirali izvori izvan Europe. Najviše sredstava, u objema godinama, prikupljeno je iz Kine, a u 2014. godini dominantni izvori bili su i iz Sjedinjenih Američkih Država. Investitori unutar regije CEE-a najviše su sredstava, iskazano u postotku, uložili u 2019. godini, kao posljedica inicijativa lokalnih vladinih agencija u Mađarskoj i Poljskoj te ulaganjem privatnih investitora na području Baltika. Slična situacija bila je i u 2015. godini, kada je postotak sredstava prikupljenih unutar regije iznosio 51 %, s fokusom na investitore iz Poljske, Češke te zemalja baltičkog područja. Europski investitori, ne uključujući regiju CEE-a, najviše sredstava uložili su u 2016., a najmanje u 2018. godini.

3.2. ULAGANJE PE U ZEMLJAMA SREDNJOISTOČNE EUROPE

Na Grafikonu 4. dan je prikaz ukupnih PE ulaganja za područje Srednjoistočne Europe u razdoblju od 2013. do 2019. godine. Od 2013. pa do 2017. godine bilježi se konstantan rast PE ulaganja. Vrhunac ulaganja postignut je u 2017. godini, kada je dosegnut iznos od 3,532 milijarde eura, što predstavlja rast od 113 % u odnosu na prethodnu godinu. Rezultat takvih razmjera posljednji put postignut je u 2008. godini s iznosom od 2,482 milijarde. Porast ulaganja u 2017. godini bio je u skladu s trendom rasta i u ostatku Europe, gdje se iznos *private equity* ulaganja u odnosu na prethodnu godinu povećao za otprilike 23 % te je iznosio 75,3 milijarde eura. Pad *private equity* ulaganja od 22 % zabilježen je u 2018. godini, međutim, promatrajući prethodne godine, uloženi iznos u promatranoj godini značajan je s vrijednosti ulaganja od 2,762 milijarde eura. U 2019. godini bilježi se ponovni rast ulaganja s iznosom od 3,272 milijarde eura, pri čemu je udio u ukupnim PE investicijama u Europi iznosio 3,2 %. Promatrajući broj poduzeća u koje se uložilo, dosegnuo se rekordni broj od 491 poduzeća, kao rezultat povećanja broja poduzeća koja su dobila *venture capital* financiranje.


Grafikon 4. PE investicije u regiji CEE-a u razdoblju od 2013. do 2019. u milijunima eura



Izvor: izrada autorice prema *Invest Europe Central and Eastern Europe Private Equity Statistics* (2015, 2016, 2017, 2018, 2019, 2021, 2022) i *EVCA Special Paper, Central and Eastern Statistics* (2013, 2014)

PE kao postotak BDP-a u regiji CEE-a proporcionalan je s iznosom investicija, što znači da se kretao po istom uzorku. U cijelom razdoblju, regija CEE-a u ostatku je u odnosu na ostatak Europe. Njezin prosjek u 2019. godini iznosio je 0,190 %, dok je europski prosjek bio triput veći, odnosno iznosio je 0,54 %. U 2019. godini, u odnosu na sve druge zemlje u Europi, Estonija i Srbija zauzele su prva dva mjesta po udjelu PE ulaganja u BDP-u s postocima od 2,462 % i 0,905 %, a Litva se našla na osmom mjestu s postotkom od 0,683 %, dok je Rumunjska imala postotak od 0,253 %, čime je prešla prosjek regije. Estonija se istaknula i u 2018. godini, kada je zauzela šesto mjesto u Europi s postotkom od 0,620 %, a u 2016., 2014. i 2013. godini njezin postotak bio je veći od prosjeka regije CEE-a. Kao i Estonija, Srbija se istaknula na višegodišnjoj razini sa svojim udjelima PE ulaganja u BDP-u pa se mogu izdvojiti 2015. i 2014. godina, u kojima se nalazila na samom vrhu u odnosu na ostatak europskih zemalja s iznosima od 0,696 % i gotovo 1 %. Ostale zemlje koje se mogu izdvojiti su Latvija, Litva i Češka jer su i one u više navrata imale postotak PE ulaganja u BDP-u veći od prosjeka regije CEE-a.

Grafikon 5. PE ulaganja kao postotak BDP-a u regiji CEE-a za razdoblje od 2013. do 2019. godine



Izvor: izrada autorica prema *Invest Europe Central and Eastern Europe Private Equity Statistics* (2015, 2016, 2017, 2018, 2019, 2021, 2022) i *EVCA Special Paper, Central and Eastern Europe Statistics* (2013, 2014)

Kao i u prethodnim godinama, u 2019. godini većina *private equity* investicija bila je koncentrirana u samo nekoliko država. Najveći iznos zabilježen je u Estoniji, čije su investicije činile 23 % svih investicija u regiji. Zatim slijede Poljska s 20 %, Rumunjska s 19 %, Srbija s 14 % i Litva s 11 %. Svih pet zemalja zajedno činile su 87 % ukupnih investicija regije Srednjoistočne Europe, a od ukupnog broja poduzeća koja su bila financirana *private equity* ulaganjima, na njih otpada 39 %. Razina godišnjih investicija u cjelokupnoj regiji, ali i u pojedinačnim zemljama može biti značajno potaknuta i samo jednom velikom transakcijom. U 2019. godini, 50 % od ukupnih investicija rezultat je četiri najveće transakcije koje su se odvale u Estoniji, Srbiji, Rumunjskoj i Litvi. Poljska se tijekom cijelog sedmogodišnjeg razdoblja istaknula kao jedna od glavnih investitora. U razdoblju od 2015. do 2018. godine razinom svojih investicija nalazila se na samom vrhu regije CEE-a. Vrhunac je postignut u 2017. godini, kada je razinom svojih investicija Poljska bila odgovorna za 71 % svih ulaganja u regiji. Značajan višegodišnji doprinos imale su i Rumunjska, Mađarska, Srbija i Češka.

Tablica 1. Ukupna PE ulaganje za zemlje regije CEE-a u razdoblju od 2013. do 2019. godine u milijunima eura

Zemlja	2013.	2014.	2015.	2016.	2017.	2018.	2019.
Bugarska	10	3	45	27	18	17	13
Češka	148	296	16	168	67	769	237
Estonija	26	23	21	81	8	160	705
Hrvatska	21	42	13	41	3	82	95
Latvija	10	51	26	26	175	10	11
Litva	22	39	49	156	6	68	331
Mađarska	58	170	194	101	209	351	166
Poljska	430	258	896	805	2505	879	589
Rumunjska	74	89	166	148	493	326	631
Slovačka	3	15	17	17	4	26	40
Slovenija	5	13	11	73	22	1	1
Srbija	13	329	229	48	2	34	417
Ukrajina	20	4	17	11	20	27	34
Ostale (BiH, Crna Gora, Moldavija, Sjeverna Makedonija)	8	0	0	0.1	1	13	2

Izvor: izrada autorica prema *Invest Europe Central and Eastern Europe Private Equity Statistics* (2015, 2016, 2017, 2018, 2019, 2021, 2022) i *EVCA Special Paper, Central and Eastern Statistics* (2013, 2014)

Kada se gleda PE ulaganje po sektorima, u 2019. godini mogu se izdvojiti četiri najznačajnija ulaganja. Najveći udio kapitala uložen je u sektor informacijske i komunikacijske tehnologije. Od ukupnog iznosa investicija, 44 %, odnosno 142 milijarde eura uloženo je u 230 poduzeća tog sektora. Na drugom mjestu našao se sektor financija i osiguranja s uloženim iznosom od 688 milijuna u 24 poduzeća, potom sektor potrošačkih dobara i usluga s iznosom od 545 milijuna eura, odnosno 17 % ukupnog iznosa investicija. U sektor poslovnih proizvoda i usluga uložilo se 280 milijuna u 76 poduzeća. U cjelokupnom razdoblju od 2013. do 2019. godine među najznačajnijim sektorima upravo se nalaze informacijska i komunikacijska tehnologija te potrošačka roba i usluge. Osim njih, u 2018. i 2016. godini istaknuli su se biotehnologija i zdravstvo s investicijama od 854 milijuna eura, odnosno 32 % ukupnih investicija, te 240 milijuna eura, odnosno 15 %, a u 2015. godini sektor energije i okoliša s 32 %.

4. UTJECAJ KRIZE UZROKOVANE PANDEMIJOM BOLESTI COVID-19 NA *PRIVATE EQUITY* TRŽIŠTE

Na kraju prosinca 2019. godine, u gradu Wuhanu u Kini započelo je širenje novog soja virusa koji je uzrokovao brojne zdravstvene probleme, a virus se vrlo brzo proširio na globalnoj razini te je 11. ožujka Svjetska zdravstvena organizacija objavila globalnu pandemiju (Invest Europe, 2021b). Pandemija bolesti COVID-19 bila je jedna od najvećih izazova s kojima se poslovni sektor susreo. Kako bi se inicijalno spriječilo širenje bolesti COVID-19 i zaštitilo zdravlje ljudi, brojne vlade donijele su restriktivne mjere, kao što su karantene, *lockdownovi*, društveno distanciranje, zatvaranje granica, nošenje maski i slično. Donesene mjere negativno su utjecale na industrije i gospodarstva diljem svijeta (Invest Europe, 2021b, Bellavitis *et al.*, 2021) te se stvorilo okruženje puno nesigurnosti u kojem su se brojna poduzeća i poduzetnici, investitori, menadžeri i sve druge poslovne osobe našle na nepoznatom teritoriju. Način poslovanja i svoje aktivnosti morali su prilagoditi brzo mijenjajućim uvjetima s ciljem minimiziranja negativnih posljedica pandemije (Invest Europe, 2021b).

Kriza uzrokovana pandemijom bolesti COVID-19 imala je i značajan utjecaj na *private equity* industriju širom svijeta. Naime, sama kriza utjecala je na sve aspekte poslovanja PE fondova, od prikupljanja sredstava, veličine ulaganja, područja ulaganja, upravljanja portfeljem te izlaznih strategija. Prikupljanje sredstava od strane PE fondova bilo je otežano zbog opreznih i pesimističnih stavova o samom tržištu te nemogućnosti dolaska do novih ograničenih partnera. S obzirom na to da su mnoge zemlje zatvorile svoje granice te nije bilo moguće putovati, menadžeri PE fondova izgubili su priliku za umrežavanje sa svojim klijentima. Nadalje, pandemija bolesti COVID-19 donijela je niz istraživačkih pitanja o *private equity* poslovanju na koje je bilo potrebno dati odgovore. Istraživačka pitanja i njihovi odgovori, odnosno rezultati pojedinih istraživanja sistematizirani su u Tablici 2.

Tablica 2. Odgovori private equityja na istraživačka pitanja

Autor	Istraživačko pitanje	Rezultati
Helmut <i>et al.</i> (2021)	PE ankete 2020. godine: Tržišno raspoloženje – utjecaj bolesti COVID-19	Iako putna ograničenja dovode do poteškoća u prikupljanju sredstava, menadžeri PE fondova ipak su optimistični u vezi s tržištima.
Kraemer-Eis <i>et al.</i> (2020)	Europski PE i VC: Utjecaj bolesti COVID-19	Europsko PE tržište doživjelo je značajan negativan utjecaj uzrokovan pandemijom bolesti COVID-19. Menadžeri smatraju da će se PE ekosustav oporaviti i postati zreliji.
Saraswati Dr C <i>et al.</i> (2020)	Studija o trendovima i razvoju PE ulaganja u Indiji	U Indiji, nedostatak dubinske analize i nedostatak osobnih sastanaka negativno su utjecali na PE ulaganja. U isto vrijeme, menadžeri fondova smanjili su nova ulaganja i zadržali oprezan stav prema budućem tržištu.
Zeidan (2020)	Održive financije i kriza uzrokovana pandemijom bolesti COVID-19	Financijski povrat glavni je cilj za PE tijekom krize uzrokovane pandemijom bolesti COVID-19. Epidemija potiče PE tvrtke na revoluciju i veću fleksibilnost.

Izvor: izrada autorica prema Chen *et al.* (2021)

Vezano uz utjecaj krize na različite industrije i sektore, potrebno je istaknuti da je isti bio neujednačen. Naime, neki sektori, kao što su tehnologije, zdravstvo i e-trgovina, doživjeli su rast potražnje, dok su, s druge strane, sektori poput turizma, putovanja i ugostiteljstva doživjeli značajne gubitke. Navedeno je utjecalo na investicijske strategije *private equity* fondova, jer su se morali prilagoditi novim trendovima te pronaći sektore koji su pokazali otpornost na krizu (Gompers *et al.*, 2022). Osim negativnog utjecaja, kriza uzrokovana pandemijom bolesti COVID-19 imala je pozitivan utjecaj na *private equity* industriju stvorivši nove niše za ulaganjem. Riječ je o potencijalu ulaganja u poduzeća koja su se bavila tehnologijom za rad od kuće, *e-learning* platformama, *online* trgovinom i zdravstvenim tehnologijama (Gompers *et al.*, 2022). Nadalje, *private equity* fondovi bili su važan izvor kapitala za poduzeća koja su se suočila s financijskim poteškoćama tijekom krize. Naime, tijekom kriza financiranje tradicionalnim izvorima ograničeno je ili nedostupno pa se velik broj poduzeća okreće PE fondovima kako bi dobili financijsku podršku za oporavak i rast (Lexa i Lexa, 2020). *Private equity* fondovi pružali su kapital za restrukturiranje poslovanja, akvizicije ili ulaganja u nove projekte, što je pomoglo poduzećima prebroditi financijske izazove izazvane krizom uzrokovanom pandemijom bolesti COVID-19. Uložena PE sredstva u poduzeća ograničenog su karakte-

ra. Naime, iz svake poduzete investicije izlazi se nakon određenog razdoblja, najčešće nakon 10-ak godina. Tijekom krize uzrokovane pandemijom bolesti COVID-19, broj ostvarenih izlaza iz poduzetih ulaganja smanjio se. Mnogi PE fondovi odgodili su planirane izlaske radi očuvanja vrijednosti svojih ulaganja te čekajući povoljnije tržišne uvjete. Navedena odgoda u izlaznoj strategiji može imati dugoročne posljedice na povrat od ulaganja fondova, kao i na likvidnost. Ono što je još potrebno istaknuti jesu promjene u regulatornom okviru koje su također utjecale na *private equity*. Naime, ovisno od zemlje do zemlje, donesene su privremene mjere koje su trebale olakšati financiranje i smanjiti administrativne prepreke za investitore, javile su se nove regulative ili su postojeće promijenjene radi lakšeg nošenja s izazovima i rizicima koje je donijela pandemija (Arundale i Mason, 2020). Sveukupno gledajući, kriza uzrokovana pandemijom bolesti COVID-19 dovela je do značajnih promjena u *private equity* industriji. Međutim, iako se očekuje značajan pad kako prikupljenih sredstava tako i razine PE ulaganja u odnosu na vrijeme prije pandemije, to ne bi trebalo biti dugoročno (Arundale i Mason, 2020, Chen *et al.*, 2021).

5. ANALIZA PE-A U REGIJI CEE-A U RAZDOBLJU OD 2020. DO 2021. GODINE


U svrhu istraživanja utjecaja pandemije bolesti COVID-19 na PE ulaganja, napravljena je detaljna analiza prikupljenih sredstava i investicija u 2020. i 2021. godini. Podaci navedene analize uspoređeni su s analizom PE-a u razdoblju od 2013. do 2019. godine.

5.1. PRIKUPLJANJE SREDSTAVA

U 2020. godini prikupljeno je 1,320 milijardi eura, što je pad od 16 % u odnosu na prethodnu, 2019. godinu. Ukupno prikupljena sredstva u Europi iznosila su 110 milijardi eura u 2020. godini, što je 4 % manje u odnosu na prethodnu godinu, a time je udio sredstava CEE-a u ukupnim sredstvima Europe pao s 1,4 % u 2019. na 1,2 % u 2020. godini. Prema analizi Invest Europe (2021c) u prvoj polovici 2020. godine pandemija nije disproporcionalno utjecala na prikupljena sredstva, odnosno bila je u skladu s povijesnim postocima. U CEE regiji, u prvoj polovici 2020. godine prikupljeno je 31 % sredstava, dok je u drugoj polovici prikupljeno 69 %. Isto je u skladu s 2019. godinom, u kojoj je 27 % sredstava prikupljeno u prvoj, a 73 % u drugoj polovici. Iz Grafikona 6.

vidljivo je kako je vrijednost prikupljenih sredstava dosegla iznos od 1,825 milijardi eura u 2021. godini, što je rast od 27 % u odnosu na prethodnu godinu. U posljednjem desetljeću veći iznos ostvaren je samo u 2018. godini. U cijeloj Europi prikupljena je 131 milijarda eura u 2021. godini, što predstavlja jedno-godišnji rast od 16 %, a sredstva CEE-a činila su 1,4 %.

Grafikon 6. Prikupljena sredstva u regiji CEE-a u razdoblju od 2019. do 2021. godine u milijunima eura



Izvor: izrada autorica prema *Invest Europe Central and Eastern Europe Private Equity Statistics* (2019, 2020, 2021, 2022)

Vladine agencije istaknule su se, kao i u prethodnim godinama, kao glavni izvor sredstava u 2020. godini te su bile zaslužne za 38 % prikupljenog kapitala od strane PE fondova. U odnosu na 2019. godinu, iznos sredstava prikupljen od strane vladinih agencija pao je za 30 %. Na drugom mjestu nalaze se bogati pojedinci s 18 % te fondovi fondova s 10 %. I u 2021. godini mogu se izdvojiti tri glavna izvora sredstava. Prevladavale su vladine agencije s 37 %, koje su prikupile 675 milijuna eura, što je rast od 35 % u odnosu na prethodnu godinu. Drugo i treće mjesto zauzeli su korporativni investitori s 14 % te fondovi fondova s 9 %.

Najviše sredstava u 2020. godini, s obzirom na geografsko područje, prikupljeno je od investitora unutar CEE regije (43 %), ali se iznos u odnosu na 2019. godinu smanjio za gotovo 50 %. Investitori iz Mađarske, Poljske, Bugarske te Hrvatske većinu su sredstava preusmjeravali u fondove *venture capitala*. Europski investitori izvan regije CEE-a nalaze se na drugom mjestu s 38 %, a potom investitori izvan Europe sa 6 %. U 2021. godini ponovno su dominirali investitori unutar regije CEE-a s 48 % u ukupno prikupljenim sredstvima, a iznos sredstava u odnosu na 2020. godinu povećao se za 37 %. Taj snažan rezul-


tat postignut je zbog inicijativa lokalnih vlada u Mađarskoj, Češkoj te zemljama baltičkog područja. Postotak sredstava prikupljenih od investitora unutar Europe, isključujući CEE, te investitora izvan Europe ostao je na istoj razini kao i u 2020. godini.

Na temelju navedenih podataka zaključuje se da se razina prikupljenih sredstava, potaknuta događajima povezanih s pandemijom bolesti COVID-19, u 2020. godini smanjila. S obzirom na izvore prikupljenih sredstava u odnosu na prethodne godine, trendovi se nisu značajno promijenili. Prevladavaju vladine agencije, fondovi fondova te investitori unutar regije CEE-a i Europe. Jedina značajna razlika, u odnosu na prethodne godine, odnosila se na strukturu *private equity* ulaganja, pri čemu su VC fondovi imali značajan rast, a *buyout* fondovi, koji su u razdoblju od 2013. do 2019. godine, s obzirom na iznos prikupljenih sredstava, bili na prvom mjestu, u 2020. imali su veliki pad od 60 %. Samo godinu dana poslije, iznos prikupljenih sredstava uspješno se oporavio. VC fondovi nalazili su se na prvom mjestu, ali su *buyout* fondovi imali jedno-godišnji rast od 52 %.

5.2. ULAGANJE PE-A

Ukupne *private equity* investicije u razdoblju od 2019. do 2021, prikazane su na Grafikonu 7. Iz istog je vidljivo kako su u 2020. investicije pale za 45 % u odnosu na prethodnu 2019. godinu. Prema izvještaju Invest Europe (2022a), pandemija bolesti COVID-19 utjecala je na iznos uloženih sredstava u pojedinim razdobljima godine. Najmanje sredstava u cijeloj Europi uloženo je u drugom kvartalu, i to samo 14,8 milijarde eura, odnosno 16 % od ukupnih investicija. U 2019. i 2018. godini u drugom kvartalu uloženo je 25 %. U prvoj polovici 2020. godine u regiji CEE-a uloženo je 0,7 milijardi eura, što je pad od 12 % u odnosu na 2019. godinu, a u drugoj polovici uloženo je 1,1 milijarda eura. Pad investicija može se također pripisati nedostatku velikih *buyout* transakcija, kojih je u prethodnim godinama znalo biti nekoliko po godini. Potrebno je istaknuti kako je u prvoj polovici 2020. godine u Europi, fokus bio na *follow-on* investicijama, odnosno dodatnim investicijama PE/VC fondova u portfelj poduzeća, što je u skladu sa zaključcima Arundalea i Masona (2020). U 2021. godini iznos ukupnih investicija narastao je za 58 % dosegnuvši rekordni iznos od 4,259 milijarde eura. Broj financiranih poduzeća u odnosu na 2020. godinu narastao je za 16 %, što je rezultat sve većeg *venture capital* financiranja te financiranja rasta (engl. *growth funding*). U ukupnim investicijama Europe, investicije regije CEE-a činile su 3 %, što je više u odnosu na 2 % iz 2020. godine.

Grafikon 7. PE investicije u regiji CEE-a u razdoblju od 2019. do 2021. u milijunima eura



Izvor: izrada autorica prema *Invest Europe Central and Eastern Europe Private Equity Statistics* (2019, 2020, 2021, 2022)


Udio PE ulaganja u BDP-u proporcionalan je s iznosom investicija. Stoga, smanjenje s 0,190 % na 0,108 % u 2020. godini nije neobično. U odnosu na ostatak Europe, regija CEE-a značajno zaostaje. Estonija se s postotkom od 1,282 % smjestila na prvo mjesto u regiji, a Hrvatska, Mađarska i Češka imale su rezultat veći od regionalnog prosjeka. U 2021. godini s ponovnim rastom PE investicija, narastao je i njihov udio u BDP-u na 0,228 %. Regija je još uvijek u značajnom zaostatku u odnosu na Europu. Kao i u 2020. godini, Estonija se s 1,547 % ponovno našla na vrhu, a Slovenija, Litva, Hrvatska i Češka imale su postotke veće od regionalnog prosjeka.

Kao i u prethodnim godinama, u 2020. godini sektor informacijske i komunikacijske tehnologije nastavio je dominirati s 41,3 %, odnosno iznosom od 745 milijuna eura u ukupno 283 poduzeća. VC ulaganja najviše su doprinijela visokoj vrijednosti ICT sektora. Na drugom mjestu smjestio se sektor biotehnologije i zdravstva s 20,5 %, odnosno 369 milijuna eura, što je rast od 78 % u odnosu na 2019. godinu. U 2021. godini ulaganja po sektorima nisu su se pretjerano razlikovala. Na prvom mjestu s 38,4 % ponovno je dominirao sektor informacijske i komunikacijske tehnologije. Unutar ICT sektora posebno se istaknula industrija aplikacijskih softvera. Ulaganja u sektor potrošačkih dobara i usluga su se povećala na 32 % pa su zauzela drugo mjesto, a sektor biotehnologije i zdravstva se smanjio na 11,8 %.

Na Grafikonu 8. prikazane su *buyout* i *growth* investicije. One su u 2020. godini dosegle iznos od 1,4 milijarde eura, što je pad od 52 % u odnosu na 2019. godinu. Najveći razlog za taj pad jest nedostatak velikih *buyout* transakcija, što

je posljedica činjenice da su se mnogi glavni partneri u uvjetima pandemijske nesigurnosti i neizvjesnosti više fokusirali na zaštitu postojećih portfeljnih poduzeća nego na potragu za novim investicijskim mogućnostima (Billio i Varotto, 2020). *Buyout* investicije zasebno u odnosu na 2019. godinu pale su za 54 %. Najveći doprinos imale su dvije velike transakcije u Estoniji i Češkoj. U 2021. godini ukupna vrijednost *buyout* i *growth* investicija udvostručila se i dosegla rekordni iznos od 3,5 milijardi eura. *Growth capital* povećao se za 48 % kao rezultat nekoliko velikih transakcija, a *buyout* investicije za 46 %.

Grafikon 8. *Buyout* i *growth* investicije u regiji CEE-a u razdoblju od 2019. do 2021. u milijunima eura



Izvor: izrada autorice prema *Invest Europe Central and Eastern Europe Private Equity Statistics* (2019, 2020, 2021, 2022)

Prema prikupljenim informacijama može se zaključiti da je pandemija bolesti COVID-19 u 2020. godini imala veći utjecaj na PE investicije i njihovu distribuciju tijekom godine u odnosu na VC investicije. Takav rezultat velikim je dijelom posljedica pada *buyout* investicija. U uvjetima neizvjesnosti, posebno u drugom kvartalu, velik broj glavnih partnera više se fokusiralo na poboljšanje postojećih portfelja s pomoću operacijskog i strateškog nadzora te *follow-on*, odnosno dodatnih investicija u odnosu na inicijalne investicije. U 2021. godini PE investicije snažno su se oporavile, pri čemu su *buyout* investicije narasle za 46 %, a VC je nastavio svoj dugogodišnji trend rasta. Tijekom 2020., ali i 2021. godine, najviše sredstava ulagalo se u sektore informacijske tehnologije i komunikacije, pri čemu su VC investicije imale najveći doprinos. Navedene informacije nisu neobične s obzirom na to da je pandemija sa sobom povukla brojne nove trendove koji su se odnosili na digitalizaciju.

6. ZAKLJUČAK

Private equity i *venture capital* tržište u CEE regiji slabije je razvijeno u odnosu na ostatak Europe. Uz kraću povijest od trideset godina, PE/VC tržište CEE regije suočeno je i sa specifičnim problemima, kao što su manjak lokalnih investitora, spor zakonodavni i regulatorni proces te nedostatak stručnog menadžerskog osoblja. Unatoč istaknutim nedostacima, PE industrija značajno je doprinijela rastu i razvoju CEE regije. Naime, u razdoblju od 2013. do 2019. godine uloženo je preko 9 milijardi eura u gotovo 3000 poduzeća. CEE regija prolazila je kroz razdoblja uspona i padova koji su u velikoj mjeri bili korelirani s događajima na svjetskoj razini. Tako se i 2019. godine suočila s pandemijom bolesti COVID-19, koja je, osim na gospodarstva zemalja, utjecala i na PE tržište. PE fondovi suočili su se s novim izazovima u pogledu ulaganja, upravljanja portfeljem i izlaza iz ulaganja. Istovremeno, kriza je stvorila nove prilike za ulaganje u sektore koji su se pokazali otpornima na krizu i za pružanje financijske podrške kompanijama u teškim vremenima. Na temelju provedene analize zaključuje se kako je kriza imala negativan utjecaj na sve segmente PE-a, od vrijednosti prikupljenog kapitala, vrijednosti ulaganja, vrijednosti ostvarenih izlaza te strukturi pojedinih PE komponenti. Naime, u 2020. godini iznos prikupljenih sredstava pao je za 16 % u odnosu na prethodnu 2019. godinu, pri čemu su *buyout* fondovi prikupili najmanje sredstava. Vrijednost im je pala za 60 %. Nadalje, pandemija je uzrokovala pad ukupnih investicija u 2020. godini. Utjecaj je bio veći na razinu PE ulaganja i njihovu distribuciju tijekom godine u odnosu na VC. To je evidentno zbog činjenice da su *buyout* i *growth* investicije pale za 52 %. Takav rezultat posljedica je nedostatka velikih *buyout* transakcija jer su se mnogi glavni partneri u uvjetima nesigurnosti više fokusirali na poboljšanje postojećeg portfelja te *follow-on* investicije. Već u 2021. godini PE tržište u CEE regiji oporavilo se i nastavilo obarati nove rekorde, što je u skladu s rezultatima istraživanja Arendulea i Masona (2020). Iznos prikupljenih sredstava narastao je za 27 % i dosegnuo iznos od 1,825 milijarde eura, dok su ukupna PE ulaganja narasla za 45 %. *Buyout* investicije također su se oporavile i narasle za 46 %. U objema godinama najviše sredstava ulagalo se u sektor informacijske i komunikacijske tehnologije, pri čemu su najveći doprinos imale VC investicije. Oporavkom u 2021. godini, tržište PE u CEE regiji pokazalo je svoju otpornost, mogućnost prilagodbe i rasta, što je u skladu i s PE tržištima u svijetu.

Ograničenje istraživanja prvenstveno je vezano uz korištenje sumiranih podataka za cjelokupnu regiju. Naime, iz njih nije vidljiv utjecaj pandemije na poje-

dinačna PE/VC tržišta. Također, može se postaviti pitanje razlike u veličini PE/VC tržišta pojedinačnih zemalja CEE regije. Navedeno može biti predmetom budućih istraživanja.

REFERENCE

1. Arundale, K. i Mason, C. (2020) Private equity and venture capital: Riding the COVID-19 crisis, str. 193-204. Billio, M. i Varott, S. (ur.) (2020) *A New World Post COVID-19, Lessons for Business, the Finance Industry and Policy Makers*, University of Reading, the Henley Business School and the ICMA Centre, Venezia.
2. Avots, K., Strenga, R., i Paalzow, A. (2013) Public venture capital in Latvia. *Baltic Journal of Economics*, Vol. 13, No. 1, str. 3-30.
3. Bellavitis, C., Fisch, C. i McNaughton, R. B. (2021) COVID – 19 and the global venture capital landscape, *Small Business Economics*, str.1–25.
4. Billio, M. i Varott, S. (ur.) (2020) *A New World Post COVID-19, Lessons for Business, the Finance Industry and Policy Makers*, University of Reading, the Henley Business School and the ICMA Centre, Venezia.
5. Bottazzi, L. (2010) Private Equity in Europe, str. 437-462. Cumming, D. *Private Equity: Fund Types, Risks and Returns, and Regulation*. John Wiley & Sons, Inc.
6. Caselli, S. i Negri, G. (2018) *Private Equity and Venture Capital in Europe: markets, techniques, and deals*. Academic Press.
7. Chen, Y., Yang, W., i Zhang, L. (2021) The impact of the COVID-19 on private equity, *3rd International Conference on Economic Management and Cultural Industry (ICEM-CI 2021)*, Atlantis Press, str. 2190-2197.
8. Cumming, D. J., i Johan, S. A. (2014) *Venture Capital and Private Equity Contracting: An International Perspective*. Academic Press.
9. Dallago, B. (2003) Small and medium – sized enterprises in Central and Eastern European countries. In Centre for Economic Institutions, Institute for Economic Research, University of Trento and Hitotsubashi University, *Tokio*. Dostupno na: Microsoft Word - smes_3.doc (hokudai.ac.jp) [15. listopada 2023.]
10. Diaconu, M. (2017) Private equity market developments in central and Eastern Europe. *Theoretical and Applied Economics Volume XXIV*, No. 2(611), str. 131-146.
11. Gompers, Paul A., Steven N. Kaplan, and Vladimir Mukharlyamov (2022) Private equity and COVID-19. *Journal of Financial Intermediation* 51 (2022): 100968.
12. Invest Europe (2014) Central and Eastern Europe Statistics 2013, https://cfo.invest-europe.eu/media/1273/_evca_bro_sp_cee2013.pdf
13. Invest Europe (2015) Central and Eastern Europe Statistics 2014, <https://www.invest-europe.eu/media/1239/evca-2014-cee-report.pdf>
14. Invest Europe (2016) Central and Eastern European Private Equity Statistics 2015, <https://if.investeurope.eu/media/1220/invest-europe-cee-statistics-2015.pdf>

15. Invest Europe (2017) Central and Eastern Europe Private Equity Statistics 2016, https://if.investeurope.eu/media/1181/invest-europe_cee_privatteequitystatistics2016_24082017.pdf
16. Invest Europe (2018) 2017 Central and Eastern Europe Private Equity Statistics, <https://if.investeurope.eu/media/1161/invest-europe-cee-activity-report-2017-05072018.pdf>
17. Invest Europe (2019), 2018 Central and Eastern Europe Private Equity Statistics, <https://www.investeurope.eu/research/activity-data/>
18. Invest Europe. (2020). 2019 Central and Eastern Europe Private Equity Statistics, <https://www.investeurope.eu/research/activity-data/>
19. Invest Europe. (2021) 2020 Central and Eastern Europe Private Equity Statistics, <https://www.investeurope.eu/research/activity-data/>
20. Invest Europe. (2021a) Private Equity in CEE Creating Value and Continued Growth, https://www.investeurope.eu/media/3595/invest-europe_private-equity-in-cee_report_final.pdf
21. Invest Europe. (2021b) The VC factor Data-driven insights into European VC and its resilience to the COVID-19 crisis. <https://www.eif.org/attachments/vc-factor-pandemic-edition.pdf>
22. Invest Europe (2021c) Investing in Europe Private Equity Activity 2020, Statistics on Fundraising, Investments & Divestments, <https://www.investeurope.eu/research/activity-data/>
23. Invest Europe (2022) 2021 Central and Eastern Europe Statistics, <https://www.invest-europe.eu/research/activity-data/>
24. Invest Europe (2022a) Investing in Europe Private Equity Activity H1 2022, <https://www.investeurope.eu/research/activity-data/>
25. Invest Europe (2023) 2022 Central and Eastern Europe Statistics, <https://www.invest-europe.eu/research/activity-data/>
26. Karsai, J. (2009) "The End of the Golden Age", The Developments of the Venture Capital and Private Equity Industry in Central and Eastern Europe. Institute of Economics, Centre for Economic and Regional Studies, Hungarian Academy of Sciences, str. 1- 60.
27. Lexa, F. J., i Lexa, F. J. (2020) Private equity-backed hospital investments and the impact of the coronavirus disease 2019 (COVID-19) epidemic. *Journal of the American College of Radiology*, 17(8), str. 1049-1052.
28. Ljumović, I., Lečovski Milojkić, I. i Obradović, V. (2020) What Drives Private Equity and Venture Capital in Central and Eastern Europe Countries: Focus on Serbia, *Economic Analysis*, Vol. 53, No. 1, str. 133-148.
29. Milenković, N., Kalaš, B. i Andrašić, J. (2020) Venture Capital and Private Equity Investment in CEE region, *X International Symposium Engineering Management and Competitiveness 2020 (EMC 2020) 19-20th June*, Zrenjanin, Serbia, str. 181-186.
30. Šimić Šarić, M. (2019). *Alternativni izvori financiranja*, Nastavni materijali, Ekonomski fakultet u Splitu.

IMPACT OF COVID-19 DISEASE ON THE PRIVATE EQUITY MARKET IN THE CEE REGION

Anamarija Mlikotić, univ. bacc. oec.

University of Split, Faculty of Economics, Business and Tourism
e-mail: amliko01@live.efst.hr

Associate Professor Marija Šimić Šarić, PhD

University of Split, Faculty of Economics, Business and Tourism
e-mail: msimic@efst.hr

ABSTRACT

Private equity (PE) and venture capital (VC) investments are significant for the economies of countries worldwide, including those in Central Eastern Europe (CEE). The PE/VC markets, like other markets, are not immune to various crises, including the one caused by COVID-19. This paper addresses the impact of the COVID-19 crisis on the PE market in CEE countries, which has not been extensively investigated. The purpose of the research is to determine the impact of the crisis on specific segments of the PE market. Based on the conducted research, it can be concluded that the crisis affected fundraising, the size of investments, portfolio management, divestments, the structure of investments, and the investment sectors. Fundraising and the size of investments decreased in 2020 compared to pre-crisis levels in 2019. The focus of the funds shifted to the existing portfolio, with less emphasis on new investments. Exits from portfolio companies were delayed, the share of venture capital investments increased, while buyout investments decreased. However, it should be noted that these changes were short-term, as the PE market recovered by 2021.

Key words: Covid 19, Private equity, CEE region, Venture capital,

JEL classification: G00, G20, G24



DIO 4: EFIKASNOST POSLOVANJA PODUZEĆA

VREDNOVANJE RELATIVNE EFIKASNOSTI POSLOVANJA HRVATSKIH PODUZEĆA TRGOVINE NA MALO

izv. prof. dr. sc. Andrea Arbula Blecich

Sveučilište u Rijeci, Ekonomski fakultet

e-mail: andrea.arbula.blecich@efri.uniri.hr

SAŽETAK

Trgovinska je djelatnost, prema udjelu BDP-a, druga najvažnija djelatnost u Hrvatskoj iza prerađivačke. S obzirom na to da konkurencija na tržištu konstantno raste, menadžment poduzeća mora donositi racionalne odluke s ciljem ostvarivanja što efikasnijeg poslovanja te osiguranja pozicije i opstanka na tržištu. Cilj ovoga rada jest vrednovati tehničku efikasnost, čistu tehničku efikasnost i efikasnost mjerila na uzorku od 116 velikih i vrlo velikih hrvatskih poduzeća trgovine na malo za 2022. godinu. Za provedbu analize korištena su tri inputa (trošak zaposlenih, materijalni trošak i ukupna imovina poduzeća) i dva outputa (profit prije poreza i operativni prihod). U radu je korištena analiza omeđivanja podataka, točnije korišteni su CCR i BCC outputu usmjereni modeli. Na ovaj način identificirana su relativno efikasna poduzeća koja mogu služiti kao primjer onim neefikasnima, kao i izvori neefikasnosti. Dobiveni rezultati otkrili su visok stupanj postignute ukupne tehničke efikasnosti, čiste tehničke efikasnosti i efikasnosti mjerila te je moguće zaključiti da je u prosjeku glavni izvor neefikasnosti promatranih poduzeća upravljanje (menadžment), tehnologija te ostali egzogeni čimbenici. Izvor neefikasnosti također predstavlja i poslovanje poduzeća na onoj veličini proizvodnje koja nije optimalna, ali je u prosjeku to manje značajno od prethodno navedenog.

Ključne riječi: *efikasnost poslovanja, trgovina na malo, analiza omeđivanja podataka, hrvatska poduzeća*

JEL klasifikacija: C67, D25, G14, M20

1. UVOD

Trgovina na malo predstavlja značajan segment gospodarstva, koji obuhvaća direktnu prodaju proizvoda i usluga potrošačima te ima ključnu ulogu u ekonomiji zemlje, pridonoseći zapošljavanju, prihodima od poreza i općem gospodarskom razvoju. Trgovina na malo jest složena gospodarska djelatnost usko povezana sa svim sektorima gospodarstva, u kojoj poduzeća i pojedinci djeluju kao posrednici između proizvodnje i potrošnje (Gupta *et al.*, 2020). Globalizacija i tehnološki napredak igraju ključnu ulogu u oblikovanju trendova u maloprodaji. Povećana digitalizacija potrošača dovodi do rasta *online* trgovine, dok se tradicionalne trgovine prilagođavaju inovativnim marketinškim strategijama i poboljšanjima iskustva kupaca. S obzirom na to da konkurencija na tržištu konstantno raste, menadžment poduzeća prisiljen je donositi sve racionalnije odluke s ciljem povećanja efikasnosti kako bi osigurao opstanak poduzeća na tržištu (Gupta i Mittal, 2010; Sharma i Choudhary, 2010). Prema klasifikaciji NACE Rev. 2, sektor trgovine (G) podijeljen je na tri podsektora: Trgovina na veliko i na malo motornim vozilima i motociklima; popravak motornih vozila i motocikala (G45), trgovina na veliko, osim trgovine motornim vozilima i motociklima (G46) i trgovina na malo, osim trgovine motornim vozilima i motociklima (G47). Predmet analize ovoga rada jesu hrvatska poduzeća iz trgovine na malo, osim trgovine motornim vozilima i motociklima (G47). U Hrvatskoj je u 2021. bilo registrirano najviše poduzeća iz područja trgovine na malo (14.721), zatim iz područja trgovine na veliko (14.498) te najmanje iz trgovine na veliko i na malo motornim vozilima i motociklima; popravak motornih vozila i motocikala (6.535) (Eurostat, 2023). S obzirom na to da je u ovome radu provedena analiza na primjeru velikih i vrlo velikih hrvatskih poduzeća iz sektora trgovine na malo, u nastavku je fokus dan upravo trgovini na malo.

Iako je vrednovanje efikasnosti poslovanja poduzeća postalo standard u istraživanjima diljem svijeta, s obzirom na važnost na taj način dobivenih rezultata za donošenje odluka u pojedinim poduzećima i organizacijama, literatura koja se bavi pitanjem vrednovanja efikasnosti maloprodajnih poduzeća u Hrvatskoj jest ograničena. Naime, postoji nedostatak istraživanja u definiranju kriterija u predlaganju sveobuhvatnog postupka vrednovanja efikasnosti poslovanja poduzeća trgovine na malo te je stoga isti u ovom istraživanju predložen. Prema saznanju autora, ne postoji sveobuhvatno istraživanje za evaluaciju efikasnosti hrvatskih poduzeća iz sektora maloprodaje.

U radu je korištena analiza omeđivanja podataka (AOMP), matematička, ne-parametrijska metoda za mjerenje efikasnosti hrvatskih poduzeća koja djelu-

ju u trgovini na malo. AOMP vrednuje relativnu, ne apsolutnu efikasnost, što neefikasnim poduzećima omogućuje usporedbu s realno mogućom izvedbom, a ne onom teorijski mogućom te se za svako neefikasno poduzeće može utvrditi koliko zaostaje za onim efikasnim.

Rad se sastoji od pet povezanih dijelova. Nakon uvoda, u drugom je dijelu dan pregled prethodnih istraživanja vrednovanja efikasnosti trgovine na malo. U trećem dijelu objašnjava se korištena metodologija, točnije, analiza omeđivanja podataka, dok se u četvrtom dijelu objašnjava izbor varijabli te se prezentiraju i objašnjavaju dobiveni rezultati. U posljednjem, petom dijelu, daje se zaključak rada.

2. PREGLED PRETHODNIH ISTRAŽIVANJA

Problemu vrednovanja efikasnosti poduzeća iz sektora trgovine na malo obično se pristupalo iz dviju perspektiva. U prvoj se vrednuje efikasnost pojedinih trgovina unutar istog trgovačkog lanca, a u drugoj se vrednuju različita poduzeća iz djelatnosti trgovine na malo. Jedno od prvih istraživanja koje je primijenilo AOMP u procjeni efikasnosti maloprodajnih trgovina jest ono Normana i Stockera (1991), dok je jedan od prvih pokušaj evaluacije produktivnosti maloprodajnih poduzeća korištenjem AOMP metode onaj autora Donthua i Yooa (1998). U radu su procijenili produktivnost 24 trgovine unutar maloprodajnog lanca restorana, koja se temelji na četiri *inputa* i dva *outputa*.

Poput Donthua i Yooa (1998), mnogi svjetski autori pisali su s aspekta prve perspektive gdje se evaluira efikasnost pojedinih trgovina unutar istog trgovinskog lanca. Upravljanje efikasnosti izvedbe trgovinskih lanaca osnovni je zadatak menadžmenta s obzirom na to da lanci trgovina obuhvaćaju velik broj distribucijskih aktivnosti i resursa (Bruce, Daly i Towers, 2004). Barros i Alves (2003) ističu kako ukupna profitabilnost trgovinskog lanca usko ovisi o ostvarenoj efikasnosti svake pojedine trgovine unutar tog lanca, zbog čega je važno vrednovati efikasnost pojedinih maloprodajnih trgovina unutar lanca. Ako postoje razlike u ostvarenoj profitabilnosti, bitno je utvrditi uzroke tome kako bi se moglo raditi na poboljšanju efikasnosti neefikasnih trgovina, čime se direktno utječe na poboljšanje efikasnosti trgovinskog lanca u cijelosti. Vyt i Cliquet (2017) razvili su standarde izvedbe koji se mogu koristiti za pravednu raspodjelu nagrada za menadžere na temelju njihove uspješnosti. U analizi su uzeli u obzir karakteristike okoline u kojoj poduzeća posluju. Koristili su AOMP

kako bi procijenili efikasnost pojedinih trgovina koje djeluju u sklopu lanca francuskog supermarketa. Povezali su uspješnost trgovina s geodemografskim varijablama. Thi Nong (2022) također je pristupio problemu efikasnosti trgovina unutar pojedinačnog lanca maloprodaje. Autor je koristio Delphi i AOMP tehnike kako bi procijenio relativnu efikasnost izvedbe maloprodajnih trgovina u modnoj industriji. Rezultati pokazuju da su najefikasnije maloprodajne trgovine smještene u dinamičnom okruženju, a veličina trgovine nema značajan utjecaj na ostvarenu efikasnost. Slično istraživanje korištenjem AOMP-a proveli su Gupta *et al.* (2020) na primjeru indijskih maloprodajnih poduzeća elektronike. Pachar *et al.* (2021) su također proveli AOMP analizu na primjeru indijskog maloprodajnog lanca trgovina sa svrhom pružanja razumijevanja pod kojim uvjetima strateške odluke na operativnoj razini uspješno podržavaju integraciju održivih operacija u upravljanju opskrbnih lanca. Rezultati pokazuju da dodatna ograničenja nastala kao rezultat održivog poslovanja dovode do poboljšane operativne efikasnosti nekih tvrtki maloprodajnog lanca i rezultiraju poboljšanom poslovnom efikasnošću, dok kod drugih poduzeća integracija održivih ciljeva smanjuje poslovnu efikasnost.

U drugoj perspektivi autori su problemu efikasnosti trgovina na malo pristupili tako da su vrednovali i uspoređivali ostvarenu efikasnost različitih poduzeća iz djelatnosti trgovine na malo. Chen, Motiwalla i Khan (2004) predložili su DEA model super-efikasnosti kako bi procijenili financijsku efikasnost maloprodajnih e-poslovnih (EB) inicijativa kako bi pravilno okarakterizirali i rangirali efikasnost raznih EB poduzeća i ne-EB poduzeća u maloprodajnom sektoru. Ova analiza pokazuje da EB poduzeća nadmašuju ne-EB poduzeća u pojedinim područjima. Okur i Ercan (2023) proveli su analizu na primjeru turske maloprodaje odjeće. Predložili su sveobuhvatan pristup za vrednovanje efikasnosti poduzeća koja posluju u djelatnosti trgovine na malo kako bi utvrdili relativnu važnost velike raznolikosti faktora specifičnih za djelatnost maloprodaje odjeće. Agarwal i Mehrotra (2019) analizirali su čimbenike koji imaju utjecaj na efikasnost šest indijskih poduzeća iz djelatnosti maloprodaje u razdoblju od sedam godina. Rezultati njihova istraživanja pokazali su da je pet od šest proučavanih indijskih maloprodajnih poduzeća barem u jednoj od sedam godina bilo neefikasno. Tri *inputa* koja istraživanje sugerira kao važne jesu upravljanje potraživanjima i zalihama (tekuća imovina), trošak oglašavanja te troškovi energije i goriva. Lukić i Hadrović-Zekić (2019) istražili su efikasnost top 14 maloprodajnih poduzeća iz Srbije, a De Jorge Moreno (2010) proveo je analizu efikasnosti maloprodajnih poduzeća iz šest europskih zemalja.

S obzirom na to da prema saznanju autora ne postoji sveobuhvatno istraživanje efikasnosti hrvatskih poduzeća iz djelatnosti maloprodaje primjenom AOMP metode, cilj rada jest istražiti navedenu temu i popuniti prazninu u postojećoj literaturi.

3. METODOLOGIJA

Efikasnost se definira kao odnos između *inputa* i *outputa*. Ako poduzeće želi poslovati efikasnije mora ili smanjiti *inpute* zadržavajući *outpute* nepromijenjene, povećati *outpute* uz istu razinu *inputa* ili, ako se *inputi* i *outputi* istodobno povećaju (ili smanje), stopa povećanja *outputa* mora biti veća od stope povećanja *inputa* i obrnuto, stopa smanjenja *outputa* mora biti manja od stope smanjenja *inputa*.

Vrednovanje relativne efikasnosti provedeno je korištenjem analize omeđivanja podataka – AOMP (engl. *Data Envelopment Analysis*), metode linearnog programiranja na osnovi procjene proizvodne funkcije koju su prvi predstavili Charnes, Cooper i Rhodes (1978). Koristi se za procjenu relativne efikasnosti homogenih donosioca odluke (DO), koje u ovom radu predstavljaju velika i vrlo velika hrvatska poduzeća iz sektora trgovine na malo. Za svakog pojedinog DO izračunava se omjer ponderiranih *inputa* i ponderiranih *outputa*, pri čemu rezultat θ može varirati između 0 i 1, pri čemu $\theta = 1$ označava efikasne DO, a $0 \leq \theta < 1$ one neefikasne. Relativno efikasni DO jesu oni koji ne mogu povećati nijedan *output*, a da pritom ne povećaju barem jedan *input*, odnosno, oni koji ne mogu smanjiti nijedan *input* bez da pritom ne smanje barem jedan od *outputa*. Usporedba relativne efikasnosti obuhvaća usporedbu između DO tako da oni relativno efikasni služe kao uzor onim relativno neefikasnima. Važno je napomenuti kako AOMP ne pruža ocjenu apsolutne efikasnosti s obzirom na to da bi to zahtijevalo jasno definiran odnos između *inputa* i *outputa*, pri čemu je teorijska razina efikasnosti (ona koju je teorijski moguće postići) poznata.

Dva osnovna AOMP modela jesu CCR i BCC model. CCR model (Charnes, Cooper i Rhodes, 1978) jest osnovni DEA model koji pretpostavlja konstantne prinose na opseg (CRS – engl. *Constant Returns to Scale*), dok BCC model (Banker, Charnes i Cooper, 1984) pretpostavlja varijabilne prinose na opseg (VRS – engl. *Variable Returns to Scale*). CRS implicira da za svakoga DO povećanje *outputa* uzrokuje proporcionalno povećanje *inputa*, dok VRS govori

kako ta povezanost ne mora nužno biti proporcionalna. Pored odabira modela, potrebno je izabrati i orijentaciju modela, odnosno odabrati je li ona orijentirana *inputima* ili *outputima*. Odabir primarno ovisi o ciljevima skupa DO koji se vrednuju, odnosno je li im primarni cilj smanjiti *inpute* ili povećati *outpute*. S obzirom na to da se u ovom radu analiza vrši na razini poduzeća, a poduzećima je prema neoklasičnoj teoriji primarni cilj maksimizacija profita (Pervan, 2020), što je ujedno i jedan od *outputa* u postavljenom modelu, u ovom radu odabrana je orijentacija usmjerena *outputima*.

U kontekstu provođenja i razumijevanja analize efikasnosti potrebno je objasniti temeljne pojmove, a to su tehnička efikasnost (TE), čista tehnička efikasnost (ČTE) i efikasnost mjerila (EM). TE pruža informacije o tome koliko se efikasno koriste resursi te o tome kolika je sposobnost njihove alokacije za svakog DO koji su u ovom istraživanju velika i vrlo velika poduzeća hrvatska poduzeća iz djelatnosti trgovine na malo. Ova mjera omogućuje nam uvid u sposobnost pojedinog DO da pretvara višestruke *inpute* u višestruke *outpute* u odnosu na njezin maksimalni potencijal. Maksimalni potencijal DO predstavlja njegovu granicu efikasnosti. Obično se pretpostavlja da se TE mjerena konstantnim prinosom na opseg (CRS), ponekad nazivana i ukupna tehnička efikasnost jer se sastoji od dviju osnovnih komponenti, ČTE i EM, odnosno, osim čiste tehničke efikasnosti također mjeri i gubitak efikasnosti koji se događa kada DO ne posluje na optimalnoj veličini. Sukladno navedenom, ČTE i EM kao osnovni dijelovi TE pružaju uvid u izvore neefikasnosti. Za razliku od TE, ČTE je pod utjecajem čimbenika poput upravljanja, tehnologije, kao i drugih egzogenih čimbenika te podrazumijeva efikasnost s varijabilnim prinosom na opseg (VRS). EM se može izračunati kao omjer TE i ČTE te pruža informacije o tome posluje li poduzeće na optimalnoj veličini resursa, odnosno optimalnoj veličini proizvodnje. DO je efikasan prema EM ako djeluje pod CRS (Kumar, Gulati, 2008).

Metoda je primarno razvijena za vrednovanje relativne efikasnosti DO iz javnog sektora, međutim, vrlo brzo su se uvidjele njezine prednosti te se počela primjenjivati i u privatnom sektoru. U današnje vrijeme AOMP se primjenjuje za vrednovanje efikasnosti u obrazovanju (Arbula Blecich, 2020; Arbula Blecich, Tomas Žiković, 2016, Sun *et al.* 2023; Taleb *et al.* 2023), zdravstvu (Asandului, Roman, Fatulescu, 2014; Dukić Samaržija, Arbula Blecich, Najdek, 2018; Khushalani, Ozcan, 2017), proizvodnoj industriji (Liang, Yang, i Ding, 2022), industriji hrane i pića (Pervan, 2021, 2020) i u mnogim drugim područjima.

4. IZBOR VARIJABLI, REZULTATI I DISKUSIJA

U ovom radu korišteni su podaci hrvatskih velikih i vrlo velikih poduzeća koja djeluju u sektoru trgovine na malo. Podaci su prikupljeni za 2022. godinu iz baze podataka Orbis Europe van Dijk. Nakon što su isključeni podaci svih poduzeća čiji su podaci nepotpuni ili imaju negativne vrijednosti odabranih *inputa* ili *outputa*, zbog čega su neprikladni za analizu, konačan broj DO bio je 116.

Ključni čimbenici koji ulaze u proizvodnu funkciju jesu rad, kapital i zemlja/materijali. U skladu s tim, u ovom su istraživanju na temelju relevantne literature odabrani sljedeći inputi: trošak zaposlenih (Barros i Perrigot, 2008; De Jorge Moreno, 2010; Donthu i Yoo, 1998; Gandhi i Shankar, 2014; Lukić i Hadrović Zekić, 2019), materijalni trošak (Pervan, 2020) i ukupna imovina (Pervan, 2020; Yu i Ramnathan, 2008) poduzeća. S druge strane, temeljni cilj poslovanja svakog poduzeća jest maksimizacija profita. Unatoč maksimizaciji profita kao temeljnog cilja poslovanja, suvremenije teorije upravljanja ističu kako poduzeća, umjesto od strane vlasnika, mogu biti pod kontrolom menadžera te se shodno tome profit više ne smatra jedinim i isključivim ciljem tvrtke. Iz perspektive menadžmenta, pored maksimizacije profita, maksimizacija prihoda se također ističe kao jedan od temeljnih ciljeva poduzeća. Sukladno navedenom, u ovom su radu kao *outputi* odabrani profit prije poreza (Agarwal i Mehrotra 2009; Balios *et al.* 2015; De Jorge Moreno, 2010; Donthu i Yoo, 1998; Gandhi i Shankar, 2014; Lukić i Hadrović Zekić, 2019; Pervan, 2020; Yu i Ramnathan, 2008, 2009) i operativni prihod (promet) poduzeća (De Jorge Moreno, 2010; Donthu i Yoo, 1998; Gandhi i Shankar, 2014; Lukić i Hadrović Zekić, 2019; Pervan, 2020; Pande i Patel, 2013; Yu i Ramnathan, 2008, 2009).

Jedan od nedostataka analize omeđivanja podataka jest taj da zbroj *inputa* i *outputa* mora biti barem 3 - 4 puta manji od broja DO. U slučaju da ovaj uvjet nije zadovoljen, značajno pada diskriminatorna moć analize. S obzirom na to da je u ovom radu ukupan broj DO 116, a ukupan zbroj *inputa* i *outputa* 5, prethodno navedeni uvjet je zadovoljen. Analiza je provedena korištenjem programa DEA Solver pro.

Prilikom odabira *inputa* i *outputa* kod provedbe AOMP-a, obavezno je da su svi *inputi* i *outputi* međusobno u pozitivnoj korelaciji, kao i to da moraju imati nenegativne vrijednosti. Korelacijska matrica za odabrane *inpute* i *outpute* prikazana je u Tablici 1.

Tablica 1. Korelacije inputa i outputa

	Trošak zaposlenih u tis. EUR	Materijalni troškovi u tis. EUR	Ukupna imovina u tis. EUR	Operativni prihod u tis. EUR	Profit prije poreza u tis. EUR
Trošak zaposlenih u tis. EUR	1	0,9508	0,9550	0,9639	0,6782
Materijalni troškovi u tis. EUR	0,9508	1	0,9645	0,9984	0,6719
Ukupna imovina u tis. EUR	0,9550	0,9645	1	0,9735	0,7244
Operativni prihod u tis. EUR	0,9639	0,9984	0,9735	1	0,694
Profit prije poreza u tis. EUR	0,6782	0,6719	0,7244	0,694	1

Izvor: autorov izračun

Vidljivo je da su sve varijable *inputa* i *outputa* međusobno pozitivno korelirane, što ukazuje na to da *output* raste s rastom *inputa*. Time je zadovoljen uvjet izotonije povezan s podacima (Wang, Nguyen i Tran, 2015) što je preduvjet za korištenjem AOMP-a.

U Tablici 2. prikazana je deskriptivna statistika korištenih *inputa* i *outputa* hrvatskih poduzeća koja se bave trgovinom na malo. Podaci ukazuju na raznolikost između odabranih poduzeća. U prosjeku, poduzeća imaju 581 zaposlenika čiji je trošak 8.364.360 eura, ukupnu imovinu od 57.681.500 eura i materijalne troškove od 75.220.700 eura. Istovremeno, prosječno poduzeće ostvaruje operativni prihod od 95.061.200 eura i dobit od 3.974.810 eura.

Tablica 2. Deskriptivna statistika (u tis. EUR)

	INPUTI			OUTPUTI	
	Trošak zaposlenih u tis. EUR	Materijalni troškovi u tis. EUR	Ukupna imovina u tis. EUR	Operativni prihod u tis. EUR	Profit prije poreza u tis. EUR
Max	134.129,00	1.279.467,00	1.008.938,00	1.596.103,00	64.101,00
Min	62,55	179,57	1.272,00	5.444,35	17,11
Average	8.364,36	75.220,70	57.681,50	95.061,20	3.974,81
SD	18.055,50	174.940,00	144.210,00	217.958,00	9.139,81

Izvor: autorov izračun

Nakon korelacijske matrice i deskriptivne statistike odabranih *inputa* i *outputa*, u sljedećoj tablici prikazani su rezultati provedene analize. Rezultati se sastoje od tehničke efikasnosti (TE), čiste tehničke efikasnosti (ČTE) i efikasnosti mjerila (EM), gdje je $\theta = 1$ pokazatelj da je DO 100 % efikasan u usporedbi s ostalim poduzećima iz uzorka, a rezultati niži od 1 ($0 \leq \theta < 1$) ukazuju na DO

koji su relativno neefikasni. Pored navedenoga, u Tablici 3. navodi se referentni skup te frekvencija efikasnih poduzeća u referentnom skupu.

Tablica 3. Relativna efikasnost velikih i vrlo velikih hrvatskih poduzeća iz sektora trgovine na malo

DMU	Naziv DMU	TE	ČTE	Referentni set	EM
DO1	KONZUM PLUS D.O.O.	0,8020	1	DO1	0,8020
DO2	LIDL HRVATSKA D.O.O. K.D.	0,8237	1	DO2	0,8237
DO3	SPAR HRVATSKA D.O.O.	0,8149	0,9823	DO1; DO2; DO7; DO8	0,8296
DO4	PLODINE D. D.	0,8090	0,9921	DO1; DO2; DO7	0,8154
DO5	KAUFLAND HRVATSKA K.D.	0,7981	0,9622	DO2; DO7; DO8	0,8295
DO6	TOMMY D.O.O.	0,8305	1	DO6	0,8305
DO7	PEVEX D.D.	0,8689	1	DO7	0,8689
DO8	AGS HRVATSKA D.O.O.	1	1	DO8	1,0000
DO9	TISAK PLUS D.O.O.	0,8447	0,9829	DO6; DO8; DO32; DO35	0,8594
DO10	DM-DROGERIE MARKT D.O.O.	0,8072	0,9952	DO1; DO6; DO7; DO35	0,8111
DO11	KTC D.D.	0,8314	0,9572	DO6; DO8; DO32; DO35	0,8686
DO12	LUKOIL CROATIA D.O.O.	0,9382	0,9700	DO6; DO7; DO8; DO32	0,9672
DO13	MULLER TRGOVINA ZAGREB D.O.O.	0,8800	0,9990	DO7; DO8; DO32	0,8809
DO14	LESNINA H. D. O. O.	0,8014	0,9380	DO7; DO32; DO35	0,8544
DO15	NARODNI TRGOVACKI LANAC D.O.O.	0,8634	0,9697	DO6; DO8; DO32; DO35	0,8904
DO16	TRGOVINA KRK D. D.	0,7858	0,9160	DO6; DO7; DO32; DO35	0,8579
DO17	FLIBA, D.O.O.	0,7614	0,8591	DO7; DO32; DO35	0,8863
DO18	FERO-TERM D.O.O.	0,8753	0,9979	DO7; DO8; DO32	0,8771
DO19	BOSO D.O.O.	0,8160	0,9067	DO6; DO7; DO8; DO32	0,9000
DO20	IKEA HRVATSKA D.O.O.	0,8021	0,9186	DO6; DO7; DO32; DO35	0,8732
DO21	BIPA D.O.O.	0,8059	0,9071	DO7; DO32; DO35	0,8884
DO22	RIBOLA, D.O.O.	0,8448	0,9013	DO7; DO8; DO32	0,9373
DO23	LJEKARNE PRIMA PHARME	0,7564	0,8117	DO7; DO8; DO32	0,9319
DO24	SPORT VISION D.O.O.	0,8229	0,8658	DO7; DO8; DO32	0,9505
DO25	GAVRANOVIC D.O.O.	0,7821	0,8397	DO6; DO8; DO32; DO35	0,9314
DO26	DECATHLON ZAGREB D.O.O.	0,9312	0,9780	DO8; DO32; DO35; DO89	0,9521
DO27	TRGOCENTAR D.O.O.	0,7849	0,8274	DO6; DO8; DO32; DO35	0,9486
DO28	GRADSKA LJEKARNA ZAGREB	0,7205	0,7732	DO7; DO32; DO35	0,9318
DO29	FARMACIA ZDRAVSTVENA USTANOVA ZA LJEKARNICKU DJELATNOST	0,8011	0,8296	DO6; DO8; DO32; DO35	0,9656
DO30	PEEK & CLOPPENBURG D.O.O.	0,9802	1	DO30	0,9802
DO31	LJEKARNA SPLITSKO-DALMATINSKE ZUPANIJE	0,7904	0,8140	DO8; DO32; DO35	0,9710

DO32	NEW YORKER CROATIA D.O.O.	1	1	DO32	1
DO33	TP VARAZDIN D.O.O.	0,7808	0,7960	DO7; DO8; DO32	0,9809
DO34	INTERSPORT H D.O.O.	0,8084	0,8341	DO7; DO8; DO32	0,9692
DO35	INA MALOPRODAJNI SERVISI D.O.O.	1	1	DO35	1
DO36	BAKMAZ, D.O.O.	0,8119	0,8363	DO8; DO32; DO35; DO89	0,9708
DO37	DEICHMANN TRGOVINA OBUCOM, D.O.O.	0,9191	0,9425	DO8; DO32; DO35; DO89	0,9752
DO38	LJEKARNE JOUKHADAR	0,7898	0,8089	DO8; DO32; DO35; DO89	0,9764
DO39	MASS SHOES D.O.O.	0,9803	0,9804	DO8; DO32; DO89; DO109	0,9999
DO40	PREHRANA TRGOVINA D.D.	0,9180	0,9490	DO8; DO32; DO35; DO89	0,9673
DO41	SVIJET MEDIJA D.O.O.	0,9003	0,9006	DO8; DO32; DO89; DO109	0,9997
DO42	DECENTIA D.O.O.	0,8587	0,8744	DO8; DO32; DO35; DO89	0,9820
DO43	SALVUS D.O.O.	0,7635	0,7659	DO8; DO32; DO49; DO86	0,9969
DO44	LA-VOR TRADE D.O.O.	0,8201	0,8290	DO8; DO32; DO35; DO89	0,9893
DO45	LJEKARNE SRCE	0,8038	0,8276	DO8; DO32; DO35; DO89	0,9712
DO46	TRI BARTOLA D.O.O.	0,9323	0,9324	DO8; DO82; DO86; DO109	0,9999
DO47	CALZEDONIA CROATIA D.O.O.	0,9310	0,9416	DO32; DO35; DO86; DO89	0,9887
DO48	VRUTAK D.O.O.	0,8301	0,8484	DO8; DO32; DO35; DO89	0,9784
DO49	TERI-TRGOVINA D.O.O.	1	1	DO49	1
DO50	JADRANKA TRGOVINA D. O. O.	0,7931	0,8026	DO8; DO32; DO35; DO89	0,9882
DO51	ZDRAVSTVENA USTANOVA ZA LJEKARNICKU DJELATNOST	0,7431	0,7440	DO32; DO49; DO86; DO92	0,9988
DO52	SLAVONIJA-BOSKOVIC D.O.O.	0,8491	0,8760	DO8; DO32; DO35; DO89	0,9693
DO53	HGSPOT GRUPA D.O.O.	0,9170	0,9175	DO8; DO32; DO86; DO109	0,9995
DO54	AKIDS HR D.O.O.	0,8547	0,8636	DO8; DO32; DO35; DO89	0,9897
DO55	LJEKARNA PABLO	0,7679	0,7728	DO8; DO32; DO35; DO89	0,9937
DO56	PPK-BJELOVAR D.D.	0,8406	0,8633	DO8; DO32; DO35; DO89	0,9737
DO57	AUTO-IVEC, OBRT ZA TRGOVINU I USLUGE, MILJENKO	0,9004	0,9023	DO8; DO49; DO82; DO86	0,9979
DO58	FASHION COMPANY D.O.O.	0,8026	0,8071	DO8; DO32; DO35; DO89	0,9944
DO59	AMEC RIJEKATEKSTIL D. O. O.	1	1	DO59	1
DO60	MAKRO D.O.O.	0,9293	0,9294	DO8; DO32; DO89; DO109	0,9999
DO61	VINDIJA TRGOVINA D.O.O.	0,9906	0,9926	DO8; DO35; DO89; DO109	0,9980
DO62	MANA MODA D.O.O.	0,8494	0,8550	DO8; DO32; DO35; DO89	0,9935
DO63	LJEKARNE ZAGREBACKE ZUPANIJE	0,8095	0,8269	DO8; DO32; DO35; DO89	0,9790
DO64	FARMACIA-SPECIJALIZIRANA PRODAVAONICA D.O.O.	0,7265	0,7522	DO32; DO35; DO86; DO92	0,9658
DO65	MONILE D.O.O.	0,7775	0,8091	DO32; DO35; DO86; DO92	0,9609
DO66	LJEKARNA JADRAN	0,7706	0,7749	DO8; DO32; DO35; DO89	0,9945
DO67	STRAHINJCICA D.O.O.	0,9542	0,9554	DO8; DO32; DO35; DO89	0,9987
DO68	LJEKARNA KASTEL FARM	0,8794	0,8836	DO8; DO32; DO49; DO86	0,9952

DO69	S. OLIVER HR D.O.O.	0,8461	0,8563	DO8; DO32; DO35; DO89	0,9881
DO70	BRODOKOMERC NOVA D. O. O.	0,8083	0,8165	DO8; DO32; DO35; DO89	0,9900
DO71	INTERMOD D.O.O.	0,8214	0,8490	DO32; DO35; DO86; DO92	0,9675
DO72	ZAGORA PROMET D.O.O.	0,9352	0,9360	DO8; DO32; DO86; DO109	0,9991
DO73	LJEKARNE SVALJEK	0,8112	0,8163	DO8; DO32; DO35; DO89	0,9938
DO74	SPINA D. O. O.	0,8471	0,8513	DO8; DO32; DO49; DO86	0,9951
DO75	POLLEO ADRIA D.O.O.	0,7388	0,7629	DO32; DO35; DO86; DO92	0,9684
DO76	NAMJESTAJ MIMA D.O.O.	0,7436	0,7637	DO32; DO35; DO86; DO92	0,9737
DO77	MANDIS-PHARM LJEKARNA ZAGREB	0,7759	0,7966	DO32; DO35; DO86; DO89	0,9740
DO78	MANGO MODA D.O.O.	0,8813	0,8888	DO8; DO32; DO35; DO89	0,9916
DO79	CENTAR TEHNIKE D.O.O.	0,9014	0,9025	DO8; DO32; DO86; DO109	0,9988
DO80	LORENCO D.O.O.	0,8464	0,8538	DO32; DO35; DO86; DO89	0,9913
DO81	VICTA D.O.O.	0,7966	0,8054	DO32; DO35; DO86; DO89	0,9891
DO82	ZERC, D.O.O.	1	1	DO82	1,0000
DO83	TOM TAILOR ZAGREB D.O.O.	0,8358	0,8381	DO32; DO35; DO86; DO89	0,9973
DO84	LJEKARNA SALUS	0,8688	0,8706	DO32; DO86; DO89; DO109	0,9979
DO85	MIKOL D.O.O.	0,9145	0,9164	DO49; DO82; DO86; DO92	0,9979
DO86	SPORT & MODA D.O.O.	1,0000	1,0000	DO86	1,0000
DO87	LJEKARNE JAGATIC	0,8072	0,8366	DO32; DO35; DO86; DO89	0,9649
DO88	GRAMEX D.O.O.	0,9665	0,9699	DO8; DO82; DO86; DO109	0,9965
DO89	FURNITURE1 D.O.O.	1	1	DO89	1
DO90	BIOPEL D. O. O.	1	1	DO90	1
DO91	TERI TRGOVINA D.O.O.	0,9099	0,9119	DO32; DO86; DO109	0,9978
DO92	B.A.M.T. D.O.O.	1	1	DO92	1
DO93	SHOEBOX ADRIA D.O.O.	0,7981	0,8296	DO32; DO35; DO86; DO89	0,9620
DO94	GT IZOLIRKA D.O.O.	0,8911	0,8949	DO32; DO86; DO89; DO109	0,9958
DO95	COLOR TRGOVINA D.O.O.	0,7751	0,8585	DO32; DO35; DO86; DO92	0,9029
DO96	MALI PALIT D. O. O.	0,7891	0,8390	DO32; DO35; DO86; DO89	0,9405
DO97	MUNIDAKOMERC D.O.O.	0,9399	0,9552	DO82; DO86; DO92; DO113	0,9840
DO98	LJEKARNA CAKOVEC	0,8389	0,8534	DO35; DO86; DO89; DO110	0,9830
DO99	Z - EL D.O.O.	0,8355	0,8410	DO32; DO35; DO86; DO89	0,9935
DO100	LJILJAN S D.O.O.	0,9118	0,9149	DO32; DO86; DO89; DO109	0,9966
DO101	LJEKARNE TRIPOLSKI	0,7709	0,8120	DO32; DO35; DO86; DO92	0,9494
DO102	LJEKARNA VARAZDINSKE ZUPANIJE	0,8341	0,8966	DO35; DO89; DO109; DO110	0,9303
DO103	PROFINE CROATIA D.O.O.	0,9138	0,9910	DO35; DO86; DO89; DO109; DO110	0,9221
DO104	ASKA D.O.O.	0,9094	0,9950	DO35; DO89; DO109; DO110	0,9140
DO105	ZLATARNA CELJE D.O.O.	0,8967	0,9779	DO86; DO89; DO109; DO110	0,9170
DO106	REVERTO, D.O.O.	0,7934	0,9472	DO35; DO86; DO89; DO110	0,8376

DO107	LJEKARNA SIBENIK	0,7822	0,8990	DO35; DO89; DO109; DO110	0,8701
DO108	LJEKARNE KALENIC	0,7575	0,8354	DO86; DO110; DO115; DO116	0,9068
DO109	TIA MOBITELI D.O.O.	0,9980	1,0000	DO109	0,9980
DO110	KARL DIETZ KIJEVO D.O.O.	0,7843	1,0000	DO110	0,7843
DO111	LJEKARNA CONER BJELOVAR	0,8059	1,0000	DO111	0,8059
DO112	TRGOVACKI OBRT P & J, VL. VLADIMIR SKEVIN, RIJEKA	0,8280	0,9278	DO35; DO89; DO109; DO110	0,8924
DO113	AGRI-VET D.O.O.	0,9708	1,0000	DO113	0,9708
DO114	IVICA & JELENA D.O.O.	0,9265	0,9725	DO86; DO109; DO115; DO116	0,9527
DO115	KRISTY, D.O.O.	0,9321	1	DO115	0,9321
DO116	LONIA D.O.O.	1	1	DO116	1
Prosjeck		0,8579	0,9032		0,9514

Izvor: autorov izračun

Rezultati TE dobiveni su korištenjem CCR modela koji podrazumijeva CRS. Od 116 poduzeća iz djelatnosti maloprodaje, njih 11 (9,5 %) ocijenjeno je efikasnim ($\theta = 1$), dok su preostala poduzeća ocijenjena neefikasnim. Relativno efikasna poduzeća formiraju granicu efikasnosti te čine referentni skup onim neefikasnim, pružajući im primjer dobre prakse. Poduzeće koje je ocijenjeno kao najneefikasnije jest DO28 s rezultatom efikasnosti od 72,05 %, što ukazuje na postojanje značajnog potencijala za poboljšanje. Za vrednovanje ČTE korišten je BCC model koji podrazumijeva VRS te prosječna vrijednost za 2022. godinu iznosi 90,32 %. Taj rezultat ukazuje na mogućnost poboljšanja efikasnosti, odnosno smanjenja neefikasnosti poduzeća tako da se *outputi* u prosjeku povećaju za 9,68 %. Budući da je 21 poduzeće ocijenjeno relativno efikasnim u pogledu ČTE (18,1 %), ona stvaraju granicu efikasnosti te se efikasnost neefikasnih poduzeća računa u odnosu na tu granicu. EM pokazuje da je 11 poduzeća iz djelatnosti trgovine na malo (9,5 %) EM efikasno, što sugerira da su ta poduzeća poslovala na optimalnoj veličini sukladno svojim *inputima* i *outputima*. Preostala su poduzeća iz uzorka EM neefikasna ($0 \leq \theta < 1$). Prosječna vrijednost EM iznosi 95,14 % te ukazuje na to da u prosjeku 4,86 % neefikasnosti proizlazi zbog odstupanja postojeće veličine proizvodnje od one optimalne sukladno ostvarenim *inputima* i *outputima*.

Sukladno rezultatima, u prosjeku je glavni izvor neefikasnosti promatranih poduzeća upravljanje, tehnologija i drugi egzogeni čimbenici. Poslovanje na veličini proizvodnje koja nije optimalna sukladno korištenim *inputima* i ostvarenim *outputima* također predstavlja izvor neefikasnosti, ali je u prosjeku

manje značajan od prethodno navedenog. Svakako valja uzeti u obzir da je svako poduzeće jedinka za sebe i da izvori neefikasnosti po pojedinom poduzeću mogu biti različiti od prosjeka (Tablica 3.). Referentni skup sadrži efikasna velika i vrlo velika hrvatska poduzeća iz djelatnosti trgovine na malo koja služe kao uzor svakom pojedinom neefikasnom DO. Istovremeno, svako efikasno poduzeće iz uzorka predstavlja istovremeno i uzor samom sebi, zbog čega je navedeno u referentnom skupu samoga sebe (Yasar, 2016).

Rezultati omogućuju stvaranje projekcija za svakog neefikasnog DO. To znači da se za svakog DO može utvrditi koliko treba povećati pojedini *output* kako bi dosegao granicu efikasnosti. S obzirom na to da je u radu korištena *output* orijentacija koja podrazumijeva povećanje *outputa* držeći pritom *inpute* nepromijenjene, u Tablici 4. prikazane su prosječne projekcije za *outpute* analiziranih poduzeća.

Tablica 4. Prosječne projekcije outputa za velika i vrlo velika hrvatska poduzeća iz sektora trgovine na malo prema BCC outputu orijentiranom modelu

	Operativni prihod u tis. EUR			Profit prije poreza u tis. EUR		
	Podaci	Projekcija	Razlika (%)	Podaci	Projekcija	Razlika (%)
Average	95.061,17	99.449,42	11,55	3.974,81	7.936,06	714,92
Max	1.596.102,7	1.596.103	34,41	64.101,0	64.101,2	10.835,08
Min	5.444,35	5.444,35	0	17,11	22,96	0
St Dev	218.903,4	219.597,8	9,81	9.179,46	10.612,3	1.717,52

Izvor: autorov izračun

U prosjeku, kako bi hrvatska maloprodajna poduzeća bila efikasna trebaju povećati operativni prihod za 11,55 % i profit prije poreza za 714,9 %. Dobiveni rezultati omogućuju razvijanje i implementaciju adekvatnih mjera poput ulaganja u promociju, jasno definiranje strategije razvoja, motiviranja i nagrađivanja zaposlenika ili optimizaciju resursa i sl., kojima bi se ostvarili bolji poslovni rezultati te omogućila bolja kontrola čimbenika od utjecaja na efikasnost promatranih poduzeća.

5. ZAKLJUČAK

Trgovina na malo u Hrvatskoj dinamična je djelatnost koja se stalno prilagođava promjenama u potražnji, tehnološkim inovacijama i zakonodavstvu. Trgovci koji uspiju poslovati efikasno imaju veće izgleda za dugoročni uspjeh na tržištu. Glavni cilj ovoga rada bio je vrednovati relativnu efikasnost poslovanja

116 velikih i vrlo velikih hrvatskih poduzeća koja posluju u gospodarskoj djelatnosti trgovine, podsektor, trgovina na malo na podacima za 2022. godinu. Za provedbu analize korišten je AOMP, točnije CCR model koji podrazumijeva CRS i BCC model koji podrazumijeva VRS, oba usmjerena na *outpute*.

Korištenje AOMP-a u kontekstu maloprodaje pruža vrijedan alat za procjenu i poboljšanje efikasnosti poslovanja. AOMP omogućuje objektivno vrednovanje efikasnosti maloprodajnih poduzeća, kako iz perspektive pojedinih poduzeća u trgovinskom lancu, tako i poduzeća na razini djelatnosti. Rezultati istraživanja ukazali su na visok stupanj postignute ukupne tehničke efikasnosti, čiste tehničke efikasnosti i efikasnosti mjerila. Moguće je zaključiti da su, u prosjeku, ključni izvori neefikasnosti u promatranim poduzećima povezani s upravljanjem, tehnologijom i ostalim vanjskim čimbenicima. Također, izvor neefikasnosti obuhvaća i poslovanje poduzeća na razini proizvodnje koja nije optimalna, iako je, u prosjeku, manje značajan u usporedbi s prethodno navedenim čimbenicima. Da bi hrvatska maloprodajna poduzeća postigla efikasnost, u prosjeku bi trebala povećati operativni prihod za 11,55 % i profit prije poreza za 714,9 %.

Dobiveni rezultati pružaju informacije o relativnoj efikasnosti različitih velikih i vrlo velikih hrvatskih maloprodajnih poduzeća, čime se pomaže u identifikiranju najboljih praksi i potencijalnih područja za optimizaciju. Ovim pristupom omogućava se usporedba s konkurentima, što je ključno za postizanje i održavanje konkurentске prednosti. Također se omogućuje menadžerima donošenje informiranih odluka o prilagodbi poslovnih strategija i resursa kako bi se poslovalo efikasno, čime se poduzećima omogućuje održavanje konkurentске pozicije, kao i opstanak u dinamičnom okruženju. Glavno ograničenje rada jest to što je analiza provedena samo za jednu godinu. U budućim istraživanjima trebalo bi analizu provesti tijekom dužeg razdoblja kako bi se utvrdio trend kretanja efikasnosti kroz vrijeme. Drugi smjer u kojem bi se trebala kretati buduća istraživanja jest, uvođenjem druge faze u istraživanju, utvrditi utjecaj makroekonomskih čimbenika na ostvarenu efikasnost.

REFERENCE

1. Agarwal, R., i Mehrotra, A. (2019) Extracting performance improvement factors using DEA for a robust Indian retail industry. *International Journal of Productivity and Quality Management*, Vol. 30, No. 1, str. 107-125.
2. Agarwal, R. i Mehrotra, A. (2009) Developing global competitiveness by assessing organized retail productivity using data envelopment analysis, *International Journal of Business Science & Applied Management*, Vol. 4, No. 2, str.1-16.

3. Arbula Bleich, A (2020) Factors affecting relative efficiency of higher education institutions of economic orientation, *Management: Journal of Contemporary Management Issues*, Vol. 25, No 1, str. 45-67.
4. Arbula Bleich, A. i Tomas Žiković, I. (2016) Evaluation of relative efficiency of higher education institutions of economic orientation, *Zbornik 5. međunarodnog znanstvenog simpozija "Gospodarstvo istočne Hrvatske – vizija i razvoj" / Proceedings of 5th International Scientific Symposium „Economy of eastern Croatia – vision and growth*, Ekonomski fakultet u Osijeku, str. 91-100
5. Asandului, L., Roman, M. i Fatulescu, P. (2014) The Efficiency of Healthcare Systems in Europe: A Data Envelopment Analysis Approach, *Procedia Economics and Finance*, Vol. 10, str. 261-268.
6. Balios, D., Eriotis, N., Fragoudaki, A. i Giokas, D. (2015) Economic efficiency of Greek retail SMEs in a period of high fluctuations in economic activity: a DEA approach, *Applied Economics*, Vol. 47, No. 33, str. 3577–3593.
7. Banker, R. D., Charnes, A. i Cooper, W. W. (1984) Some models for estimating technical and scale inefficiencies in data envelopment analysis, *Management Science*, Vol. 30, No. 9, str. 1078–1092.
8. Barros, C. P. i Alves, C. A. (2003) Hypermarket retail store efficiency in Portugal, *International Journal of Retail & Distribution Management*, Vol. 31, No. 11, str. 549-560.
9. Barros, C. P. i Perrigot, R. (2008) Technical efficiency of French retailers, *Journal of Retailing and Consumer Services*, Vol. 15, No. 4, str. 296–305.
10. Bruce, M. , Daly, L. i Towers, N. (2004) Lean or agile: a solution for supply chain management in the textiles and clothing industry?, *International Journal of Operations & Production Management*, Vol. 24, No. 2, str. 151-170.
11. Charnes, A, Cooper, W. W. i Rhodes, E (1978) Measuring the efficiency of decision making units, *European Journal of Operational Research*, Vol. 2, No. 6, str. 429-444
12. Chen Y., Motiwalla, L. i Khan, M. R. (2004) Using super-efficiency dea to evaluate financial performance of e-business initiative in the retail industry, *International Journal of Information Technology & Decision Making*, Vol. 03, No. 02, str. 337-351.
13. Cooper, W. W., Seiford, L. M. i Tone, K. (2007) *Data Envelopment Analysis - A Comprehensive Text with Models, Applications, References and DEA-Solver Software*, Second edition, Springer Science+Business Media, LLC
14. De Jorge Moreno, J. (2010) Productivity growth of European retailers: a benchmarking approach, *Journal of Economic Studies*, Vol. 37, No. 3, str. 288–313.
15. Donthu, N. i Yoo, B. (1998) Retail productivity assessment using data envelopment analysis, *Journal of Retailing*, Vol. 74, No. 1, str. 89–105.
16. Dukić Samaržija, N., Arbula Bleich, A. i Najdek, T. (2018) Investigation of the Reimbursement Scheme in Croatian Public Hospitals: a Data Envelopment Analysis Approach, *Economic and Social Development - 28th International Scientific conference on Economic and Social Development*, Paris, str. 358-366.

17. Eurostat (2023) *Enterprise statistics by size class and NACE Rev.2 activity (from 2021 onwards)* Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/sbs_sc_ovw__custom_10247476/default/table?lang=en, [7. studenoga 2023.]
18. Gandhi, A. i Shankar, R. (2014) Efficiency measurement of Indian retailers using data envelopment analysis, *International Journal of Retail and Distribution Management*, Vol. 42, No. 6, str. 500–520.
19. Gupta, A. i Mittal, S. (2010) Measuring retail productivity of food & grocery retail outlets using the DEA technique, *Journal of Strategic Marketing*, Vol. 18, No. 4, str. 277–289.
20. Gupta, A., Pachar, N., Jha, P. C. i Darbari, I. D. (2020) Efficiency assessment of Indian electronics retail stores using DEA, *International Journal of Business Performance and Supply Chain Modelling*, Vol. 10, No. 4, str. 386–414.
21. Khushalani, J. i Ozcan, Y. A. (2017) Are hospitals producing quality care efficiently? An analysis using Dynamic Network Data Envelopment Analysis (DEA), *Socio-Economic Planning Sciences*, 60 (December), str. 15–23.
22. Kumar, S. i Gulati, R. (2008) An Examination of Technical, Pure Technical, and Scale Efficiencies in Indian Public Sector Banks using Data Envelopment Analysis, *Eurasian Journal of Business and Economics*, Vol. 1, No.2, str. 33–69.
23. Liang, S., Yang, J. i Ding, T. (2022) Performance evaluation of AI driven low carbon manufacturing industry in China: An interactive network DEA approach, *Computers & Industrial Engineering*, 170, str. 108248.
24. Lukić, R. i Hadrović-Zekić, B. (2019) Evaluation of efficiency of trade companies in Serbia using the DEA approach, *Proceedings of The 19th International Scientific Conference Business Logistics in Modern Management*, Dostupno na: <https://hrcak.srce.hr/ojs/index.php/plusm/article/view/10353> [11. studenoga 2023.]
25. Norman, M., i Stoker, B. (1991) *Data Envelopment Analysis: The Assessment of Performance*. New York, United States: John Wiley & Sons, Inc
26. Okur, N. i Ercan, T. (2022) Evaluating retail efficiency using DEA and AHP: a case in the Turkish apparel retail industry, *Journal of Fashion Marketing and Management*, 10.1108/JFMM-06-2021-0154
27. Pachar, N., Darbari, J. D., Govindan, K. i Jha, P. C. (2021) Sustainable performance measurement of Indian retail chain using two-stage network DEA. *Ann Oper Res*. <https://doi.org/10.1007/s10479-02104088-y>
28. Pande, S. i Patel, G. N. (2013) Assessing cost efficiency of pharmacy retail stores and identification of efficiency drivers, *International Journal of Business Performance Management*, Vol. 14, No. 4, str.368–385.
29. Pervan, M. (2021) Pure Technical Efficiency and Its Determinants-The Case of Croatian Beverage Industry. In *6th International Conference on Education Reform and Modern Management (ERMM 2021)*, str. 297–300. Atlantis Press.

30. Pervan, M. (2020) Efficiency of large firms operating in the Croatian food industry: Data envelopment analysis, *WSEAS transactions on business and economics*, Vol 17, str. 487-495.
31. Sharma, V. i Choudhary, H. (2010) Measuring operational efficiency of retail stores in Chandigarh Tri-city using DEA, *Journal of Services Research*, Vol. 10, No. 2, str. 99-115.
32. Sun, Y., Wang, D., Yang, F. i Ang, S. (2023) Efficiency evaluation of higher education systems in China: A double frontier parallel DEA model, *Computers & Industrial Engineering*, 176, str. 108979.
33. Taleb, M., Khalid, R., Attallah, M., Kareem, Q. A., i Ramli, R. (2023) Assessing and ranking the performance of higher education institutions: a non-radial super efficiency DEA approach. *International Journal of Education Economics and Development*, Vol. 14, No. 2, str. 213-230.
34. Thi Nong, N.-M. (2022) An application of delphi and dea to performance efficiency assessment of retail stores in fashion industry, *The Asian Journal of Shipping and Logistics*, Vol. 38, No. 3, str. 135-142.
35. Yasar A. O. (2016) *Health care benchmarking and performance evaluation: An assessment using Data envelopment analysis*, Springer
36. Yu, W. i Ramanathan, R. (2008) An assessment of operational efficiencies in the UK retail sector, *International Journal of Retail and Distribution Management*, Vol. 36, No. 11, str. 861-882.
37. Yu, W. i Ramanathan, R. (2009) An assessment of operational efficiency of retail firms in China, *Journal of Retailing and Consumer Services*, Vol 16, No. 2, str. 109-122.
38. Vyt, D. i Cliquet, G. (2017) Towards a fairer manager performance measure: a DEA application in the retail industry, *The International Review of Retail, Distribution and Consumer Research*, Vol. 27, No. 5, str. 450-467.
39. Wang, C. N., Nguyen, N. T. i Tran, T. T. (2015) Integrated DEA Models and Grey System Theory to Evaluate Past-to-Future Performance: A Case of Indian Electricity Industry, *The Scientific World Journal*, Vol 2015, str. 1-17.

EVALUATION OF THE RELATIVE EFFICIENCY OF CROATIAN RETAIL COMPANIES

Associate Professor Andrea Arbula Blecich, PhD

University of Rijeka, Faculty of Economics and Business

e-mail: andrea.arbula.blecich@efri.uniri.hr

ABSTRACT

In terms of its share of GDP, trade is the second most important economic sector in Croatia after manufacturing. As market competition intensifies, company management must make rational decisions to achieve optimal efficiency and secure their market position and survival. The aim of this paper is to evaluate technical efficiency, pure technical efficiency, and scale efficiency based on a sample of 116 large and very large Croatian retail companies for the year 2022. Four inputs (cost of employees, material costs, and total assets of the company) and two outputs (profit before tax and operating income) were used for the analysis. Data Envelopment Analysis (DEA) was employed, specifically using CCR and BCC output-oriented models. This approach identified relatively efficient companies, which can serve as references for inefficient companies, and pinpointed the sources of inefficiency. The results indicate a high level of overall technical efficiency, pure technical efficiency, and scale efficiency. It can be concluded that the main sources of inefficiency among the observed companies are, on average, management, technology, and other exogenous factors. Another source of inefficiency is the non-optimal production size of the company, although this factor is generally less significant than the aforementioned factors.

Key words: company efficiency, retail trade, Data Envelopment Analysis, Croatian companies

JEL classification: C67, D25, G14, M20

ODREDNICE DRŽANJA NOVCA S OBZIROM NA DJELATNOST I VELIČINU PODUZEĆA U REPUBLICI HRVATSKOJ

Romina Antić, mag. oec.

Sveučilište u Rijeci, Ekonomski fakultet
e-mail: romina.antic@efri.uniri.hr

izv. prof. dr. sc. Ivana Tomas Žiković

Sveučilište u Rijeci, Ekonomski fakultet
e-mail: ivana.tomas.zikovic@efri.uniri.hr

izv. prof. dr. sc. Kazi Sohag

Ural Federal University, Graduate School of Economics and Management
Sveučilište u Rijeci, Ekonomski fakultet
e-mail: sohagkaziewu@gmail.com
e-mail: kazi.sohag@efri.hr

SAŽETAK

Za uspješno poslovanje poduzeća ključna je odgovarajuća razina likvidnosti, što uključuje i primjerenu količinu novca na transakcijskim računima poduzeća. Stoga je svrha ovog istraživanja ispitati utjecaj različitih odrednica, poput profitabilnosti, zaduženosti, potencijala rasta, starosti, djelatnosti i veličine poduzeća, te makroekonomskog okruženja na držanje novca u poduzeću. Nadalje, cilj rada jest ispitati postoje li razlike u utjecaju navedenih odrednica na držanje novca s obzirom na djelatnost i veličinu poduzeća. Analiza je provedena na uzorku od 19.818 poduzeća u Republici Hrvatskoj u okviru trgovinske, građevinske i prerađivačke djelatnosti. Rezultati panel-analize ukazuju na to da na intenzivnije držanje novca utječu viša profitabilnost, neto radni kapital, potencijal rasta, zaduženost, financijski rizik i starost poduzeća, dok se držanje novca smanjuje s povećanjem investicijske aktivnosti i rastom BDP-a. Također, rezultati ukazuju na značajne razlike u odrednicama držanja novca promatrano po kategorijama veličine poduzeća, dok analiza na razini djelatnosti poduzeća ne ukazuje na značajne razlike u odrednicama. Kada se poduzeća grupiraju prema

vrsti djelatnosti i veličini, najveće varijacije u odrednicama držanja novca primijećene su kod poduzeća građevinske djelatnosti.

Ključne riječi: *odrednice držanja novca, panel-analiza, građevinska djelatnost, prerađivačka djelatnost, trgovinska djelatnost, veličina poduzeća*

JEL klasifikacija: G30, G32, C23

1. UVOD

Na savršenim tržištima kapitala, odluka o držanju novca je irelevantna jer poduzeća mogu lako generirati sredstva s financijskih tržišta kako bi financirala vlastita ulaganja uz zanemarive troškove (Aftab *et al.*, 2018). Držanje novca u poduzećima ovisi o čimbenicima koji su specifični za samo poduzeće i o općoj makroekonomskoj situaciji u državi u kojoj poduzeće posluje. Novac na transakcijskim računima predstavlja izvor financiranja poslovanja, posebno za mala i srednja poduzeća koja nemaju pristup pozajmljivanju sredstava na financijskim tržištima.

Analiza je provedena na trgovačkim društvima kapitala, uključujući dionička društva i društva s ograničenom odgovornošću, koja posluju u Republici Hrvatskoj. Pritom su obuhvaćena poduzeća koja posluju u sklopu prerađivačke, trgovinske i građevinske djelatnosti, koje čine značajan udio u ukupnoj ekonomskoj aktivnosti. Cilj rada jest razumijevanje odrednica koje utječu na odluke poduzeća o zadržavanju novca te razlike u utjecaju odrednica uvažavajući vrstu djelatnosti i kategoriju veličine poduzeća. Djelatnost poduzeća može imati značajnu ulogu u odlučivanju o držanju novca s obzirom na specifičnost svake djelatnosti. Primjerice, poduzeća u području trgovine imaju veću potrebu za novcem radi svakodnevnih transakcija i plaćanja dobavljačima, dok poduzeća u drugim djelatnostima mogu imati manju potrebu za novcem zbog manje ovisnosti o gotovinskim transakcijama. Veličina poduzeća također može utjecati na razinu novca pa tako manja poduzeća koja su, u pravilu, izloženi financijskim rizicima i ograničenim izvorima financiranja mogu imati veću potrebu za držanjem novca. Veća poduzeća obično raspolazu većim financijskim resursima i pristupom raznim izvorima financiranja, što može utjecati na njihovu potrebu za držanjem novca na transakcijskim računima.

Slijedom navedenog, predmet istraživanja je analiza odrednica koje utječu na držanje novca u poduzećima s posebnim naglaskom na vrstu djelatnosti (građevinska, trgovinska i prerađivačka) i kategorije veličine poduzeća (ma-

lih i srednjih, te velikih i vrlo velikih poduzeća). Navedeno predstavlja ključni doprinos rada jer dosadašnja istraživanja nisu analizirala razlike u utjecaju odrednica s obzirom na veličinu i djelatnost poduzeća.

Empirijsko istraživanje temelji se na sekundarnim podacima iz baze podataka Orbis Europe, iz koje je preuzet uzorak od 19.818 poduzeća koja posluju u Hrvatskoj u okviru djelatnosti trgovine, građevinarstva i prerađivačke industrije. Prikupljeni podaci obuhvaćaju informacije iz financijskih izvještaja poduzeća, financijske omjere te druge opće podatke o poslovanju poduzeća.

U prvom dijelu rada uvodi se u problematiku i predmet istraživanja, dok je u drugom dijelu prikazan pregled prethodnih istraživanja. U trećem dijelu opisane su odrednice držanja novca, a u četvrtom dijelu opisana je metodologija koja se koristi za provođenje analize, obilježja uzorka i definicije varijabli. Peti dio sadrži rezultate istraživanja o odrednicama držanja novca u poduzećima koja se bave trgovinom, građevinskom i prerađivačkom djelatnošću. Zaključci istraživanja, oblikovani na temelju empirijske analize, prikazani su u šestom dijelu.

2. PREGLED PRETHODNIH ISTRAŽIVANJA

U nastavku se analiziraju odrednice prema prethodnim istraživanjima gdje se, pored poduzeću specifičnih faktora, proučava i utjecaj makroekonomskog okruženja na držanje novca u poduzeću.

Aftab *et al.* (2018) analizirali su držanje novca u poduzećima u šest regija svijeta u razdoblju od 2007. do 2016. godine. Njihovi zaključci ukazuju na snažnu povezanost između držanja novca i faktora, poput veličine poduzeća, *Z-scorea*, investicija i novčanih tokova. Također, ističu da se držanje novca u poduzećima smanjuje s povećanjem financijske poluge, isplatom dividendi, rastom nematerijalne imovine, profitabilnosti i neto radnog kapitala. Razlike u držanju novca među poduzećima u različitim dijelovima svijeta pripisuju varijacijama u dioničarskim pravima, korporativnom upravljanju i financijskom razvoju.

Ozkan i Ozkan (2004) i Al-Najjar i Belghitar (2011) analizirali su držanje novca na uzorku poduzeća iz Ujedinjenog Kraljevstva. Prvi autori potvrdili su negativnu vezu između novčanih tokova, likvidnosti i financijske poluge s držanjem novca, dok su Al-Najjar i Belghitar (2011) pronašli pozitivan utjecaj dividendne politike, poluge, rasta poduzeća, veličine, rizika, profitabilnosti i neto radnog kapitala. Važnost razmatranja utjecaja dividendnih politika na držanje novca naglasili su i Kwan i Lau (2020) na uzorku malezijskih poduzeća.

Odrednice držanja novca u poduzećima u članicama ekonomske i monetarne unije istražili su Ferreira i Vilela (2004), čiji rezultati upućuju na pozitivan utjecaj investicijskih mogućnosti i negativan utjecaj supstituta likvidnih sredstava i financijske poluge. Također su potvrdili negativan utjecaj veličine poduzeća, bankovnih kredita i neto radnog kapitala na držanje novca. Zaključke prethodnih istraživanja o negativnom utjecaju neto radnog kapitala na držanje novca potvrdili su i Ali i Yousaf (2013) na uzorku njemačkih poduzeća. Garcia-Teruel i Solano (2008) na uzorku 860 malih i srednjih španjolskih poduzeća pronašli su negativnu povezanost držanja novca s likvidnošću, veličinom poduzeća, dospijecom duga, kamatnim stopama i BDP-om, dok je istodobno potvrđen pozitivan utjecaj novčanih tokova, rasta poduzeća, financijskih poteškoća i poluge. Guney *et al.* (2003) ispitali su odrednice držanja novca na poduzećima iz Japana, Francuske, Njemačke i Ujedinjenog Kraljevstva u razdoblju od 1983. do 2003. godine. Pored ostalih odrednica, razmotrili su važnost korporativnog upravljanja te pravnih i institucionalnih odrednica kao stupanj zaštite vjerovnika, indeks vladavine prava i koncentracija vlasništva. Veća prava vjerovnika pozitivno utječu na držanje novca, dok veća prava dioničara i viša koncentracija vlasništva rezultira nižim držanjem novca. Dittmar *et al.* (2003) na uzorku poduzeća iz 45 zemalja dokazali su pozitivan utjecaj zaštite vlasničkih prava na držanje novca. Držanje novca u poduzećima u negativnoj je vezi s veličinom poduzeća i radnim kapitalom, dok, istovremeno, omjer tržišne i knjigovodstvene vrijednosti, novčani tokovi i nematerijalna imovina pozitivno doprinose toj dinamici.

Opler *et al.* (1999), Pinkowitz *et al.* (2015) i Martinez-Sola *et al.* (2011) analiziraju odrednice držanja gotovine na uzorku poduzeća iz SAD-a. Opler *et al.* (1999) nalaze da poduzeća s većim potencijalom rasta i višim rizikom poslovanja drže više novca na transakcijskim računima, dok ona s boljim pristupom tržištu kapitala drže manje novca. Rezultati potvrđuju i negativnu povezanost s veličinom poduzeća, neto radnim kapitalom i polugom, te pozitivnu povezanost s novčanim tokovima i kapitalnim izdacima. Pinkowitz *et al.* (2015) nisu pronašli značajne razlike u odrednicama držanja novca između američkih poduzeća i njihovih inozemnih partnera nakon krize iz 2008. godine, dok je istraživanje Martinez-Sola *et al.* (2011) ukazalo na pozitivan, konkavan odnos između držanja novca i vrijednosti poduzeća. Autori nalaze i da negativan utjecaj na držanje novca imaju visoka likvidnost, financijska poluga, nematerijalna imovina i veličina poduzeća, dok novčani tokovi pozitivno utječu na razinu novca u poduzećima.

Sethi i Swain (2019) pronalaze da na veće držanje novca u prerađivačkim indijskim poduzećima značajno utječu veća mogućnost rasta, visoka poluga, viši novčani tokovi, isplaćene dividende, pozitivan neto radni kapital, viša profitabilnost, te značajni izdaci za istraživanje i razvoj, dok negativno utječu veličina poduzeća i kamatne stope. Arfan *et al.* (2017) analizirali su determinante držanja novca u prerađivačkim poduzećima Indonezijske burze zaključujući da mogućnost rasta i profitabilnost pozitivno utječu, dok poluga i veliki kapitalni izdaci imaju negativan utjecaj. Al-Najjar (2013) analizirao je odrednice držanja novca u poduzećima Brazila, Rusije, Indije i Kine, uspoređujući ih s rezultatima istraživanja provedenih na poduzećima iz SAD-a i Ujedinjenog Kraljevstva. Njegovi zaključci ukazuju na zajedničke financijske odrednice među poduzećima obiju skupina zemalja, uključujući financijsku polugu, isplatu dividendi, likvidnost, profitabilnost i veličinu poduzeća. Dividendna plaćanja, likvidnost i poluga imaju negativan utjecaj na držanje novca, dok profitabilnost i veličina poduzeća imaju pozitivan utjecaj. Batuman *et al.* (2021) analizirali su slične odrednice kao i Al-Najjar (2013) te su zaključili kako navedene odrednice značajno utječu na držanje novca u poduzećima istočne Europe. Isto je u svojem istraživanju potvrdio i Naumoski (2018), koji kao ključne odrednice držanja novca u poduzećima iz jugoistočne Europe nalazi neto radni kapital (likvidnost), veličinu poduzeća, financijsku polugu, dividendne politike i novčani tok. Pored ostalih odrednica, Tong (2011) je pronašao značajnu povezanost između diversifikacije poduzeća i držanja novca i zaključio da diversificirana poduzeća drže manje novca, dok su Ki i Adhikari (2022) dokazali da rast bruto domaćeg proizvoda (BDP-a) pozitivno utječe na držanje novca u poduzećima, dok inflacija ima suprotan, negativan učinak.

3. ODREDNICE DRŽANJA NOVCA

Na temelju prethodno izloženih istraživanja, u nastavku se analizira utjecaj ključnih odrednica držanja novca, i to: profitabilnosti, novčanih tokova, neto radnog kapitala, investicija (kapitalnih izdataka), mogućnosti rasta poduzeća, financijske poluge, vjerojatnosti financijskih poteškoća, veličine i starosti poduzeća te varijabli iz makroekonomskog okruženja.

Očekuje se pozitivan utjecaj profitabilnosti na držanje novca u poduzeću, jer profitabilnija poduzeća imaju veću sposobnost servisiranja obveza i zadržavanja više novca, što je u skladu s teorijom hijerarhije financijskih izbora (Aftab *et al.*, 2018; Al Najjar i Belghitar, 2011; Sethi i Swain, 2019; Arfan *et al.*, 2017).

S druge strane, prema teoriji kompromisa profitabilnija poduzeća drže manje novca jer je profit neposredan izvor likvidnosti.

Za neto radni kapital, koji je poznat i kao supstitut likvidnosti, prema teoriji kompromisa očekuje se negativan utjecaj na držanje novca. Porastom neto radnog kapitala, poduzeća će držati manje novca s obzirom na to da je trošak likvidacije tekuće imovine u gotovinu mnogo niži od prodaje druge imovine, što je potvrđeno u Aftab *et al.* (2018), Ozkan i Ozkan (2004), Dittmar *et al.* (2003) i Opler *et al.* (1999). S druge strane, Sethi i Kumar Swain (2019) nalaze da poduzeća s većim neto radnim kapitalom drže više novca. To objašnjavaju činjenicom kako poduzeća s kraćim ciklusima konverzije gotovine brzo pretvaraju svoj radni kapital u gotovinu, što rezultira većim držanjem novca te poduzeća većinu neto radnog kapitala drže u obliku visoko likvidne imovine.

Prema teoriji kompromisa, novčani tokovi predstavljaju vrstu zamjene za novac pa poduzeća s višim novčanim tokovima obično drže manje novca. Međutim, postoje i istraživanja koja ukazuju na suprotnu dinamiku, gdje poduzeća s višim novčanim tokovima preferiraju zadržavanje više novca u poduzeću, što je u skladu s teorijom hijerarhije financijskih izbora (Kwan i Lau, 2020; Opler *et al.*, 1999; Mesfin, 2016; Garcia-Teruel i Solano, 2008; Ali i Yousaf, 2013). Stoga, nije moguće jednoznačno predvidjeti utjecaj novčanih tokova na držanje novca u poduzećima.

Kapitalni izdaci rezultiraju značajnim odljevom novca u poduzeću te će, prema Kwan i Lau (2020), poduzeća s visokim kapitalnim izdacima najprije koristiti svoje novčane rezerve, a potom vanjske izvore financiranja, što je u skladu s teorijom financijskih izbora. Stoga se očekuje negativna povezanost između ovih dviju varijabli. S druge strane, Aftab *et al.* (2018) ističu nekoliko istraživanja koja su pokazala pozitivnu povezanost između kapitalnih izdataka i držanja novca s obzirom na to da poduzeća koja drže više gotovine, između ostalog, imaju više mogućnosti za ulaganje u slučaju većih financijskih poteškoća na tržištu i unutar poduzeća. Stoga, nije moguće precizno odrediti kako će kapitalni izdaci utjecati na zadržavanje gotovine.

Prema teoriji kompromisa i teoriji financijskih izbora, očekuje se pozitivan utjecaj rasta poduzeća na držanje novca. Mogućnost rasta poduzeća mjeri se omjerom tržišne i knjigovodstvene vrijednosti poduzeća, a ako u uzorku prevladavaju poduzeća koja ne kotiraju na burzi, rast poduzeća može se izraziti varijablom koja označava rast prodaje. Prethodna istraživanja sugeriraju pozitivnu povezanost između mogućnosti rasta poduzeća i držanja novca, jer se

brzorastuća poduzeća oslanjaju najprije na vlastita novčana sredstva za financiranje rasta i sprečavanje potencijalnih šteta u poduzeću (Aftab *et al.*, 2018; Kwan i Lau, 2020).

Nije moguće jednoznačno predvidjeti utjecaj financijske poluge na držanje novca u poduzeću. S jedne strane, poduzeća s visokom financijskom polugom drže više novca jer poluga povećava vjerojatnost financijskih poteškoća (Kwan i Lau, 2020; Al Najjar i Belghitar, 2011; Garcia-Teruel i Solano, 2008; Sethi i Swain, 2019). S druge strane, što poduzeće koristi više duga, to je manja potreba za držanjem novca (Aftab *et al.*, 2018; Opler *et al.*, 1999; Ferreira i Vilela, 2004).

Volatilnost dobiti prije plaćanja poreza i kamata koristi se kao mjerilo vjerojatnosti financijskih poteškoća. Poduzeća koja se suočavaju s većim rizikom od financijskih poteškoća imaju tendenciju zadržavati više gotovine kako bi izbjegla vanjska financijska ograničenja (Opler *et al.*, 1999; Aftab *et al.*, 2018).

U ekonometrijskim modelima uobičajeno je kao mjeru veličine poduzeća koristiti logaritam ukupne imovine. U skladu s teorijom kompromisa, očekuje se da će veća poduzeća držati manje novca u odnosu na ukupnu imovinu poduzeća, te će imati prednost u odnosu na manja poduzeća jer im nisu potrebne velike rezerve novca zbog ekonomije obujma i manje informacijske asimetrije (Aftab *et al.*, 2018; Kwan i Lau, 2020; Garcia-Teruel i Solano, 2008; Opler *et al.*, 1999; Martinez-Sola *et al.*, 2011; Sethi i Swain, 2019; Dittmar *et al.*, 2003).

Starost poduzeća često se povezuje s iskustvom poduzeća te je za očekivati kako će starija/iskusnija poduzeća držati više novca kako bi bili spremni na nepredvidive situacije (Hussain *et al.*, 2020). Međutim, prethodna istraživanja sugeriraju negativnu povezanost između starosti poduzeća i držanja novca, tj. mlađa poduzeća imaju veću tendenciju držanja novca od starijih poduzeća (Sethi i Swain, 2019).

Što se tiče utjecaja eksternih odrednica, odnosno varijabli iz ekonomskog okruženja, Chen *et al.* (2016) pronašli su negativnu vezu između rasta bruto domaćeg proizvoda (BDP) i držanja novca, odnosno menadžeri preferiraju veće držanje novca u slučaju nepovoljnih ekonomskih uvjeta. S druge strane, Ki i Adhikari (2022) i Mesfin (2019) otkrili su da će poduzeća držati više novca u uvjetima rasta BDP-a s obzirom na niže troškove vanjskog financiranja i manjih financijskih ograničenja u uvjetima ekonomskog prosperiteta. Pozitivna veza sugerira da, u iščekivanju povoljnih gospodarskih uvjeta, poduzeća drže više novca kako bi imala dovoljno internih sredstava kada se pojave profita-

bilne prilike za ulaganje. Oprečni rezultati istraživanja ukazuju na složenost utjecaja makroekonomskih uvjeta na držanje novca u poduzećima.

4. METODOLOGIJA, OPIS VARIJABLI I UZORAK ISTRAŽIVANJA

U nastavku se opisuju korištene varijable povezane s držanjem novca te uzorak poduzeća koji obuhvaća subjekte u okviru djelatnosti trgovine, građevinarstva i prerađivačke djelatnosti na području Republike Hrvatske.

4.1. OPIS VARIJABLI I UZORKA ISTRAŽIVANJA

Uzorak za analizu preuzet je iz baze podataka Orbis Europe, koja obuhvaća informacije o poduzećima diljem Europe. Navedena baza podataka korištena je za prikupljanje podataka o svim dioničkim društvima i društvima s ograničenom odgovornošću u RH koja se prema klasifikaciji NAICS 2017. bave: trgovinskom djelatnošću: 42 – veleprodaja, 44 – maloprodaja, 45 – maloprodaja; građevinskom djelatnošću: 23 – građevinska djelatnost, i prerađivačkom djelatnošću: 31 – proizvodnja, 32 – proizvodnja, 33 – proizvodnja.

Promatrano razdoblje obuhvaća financijske pokazatelje i informacije o poduzećima u razdoblju od 2016. do 2021. godine. Iz uzorka su isključena poduzeća koja nemaju podatke o ukupnoj imovini, novcu i novčanim ekvivalentima, dugotrajnoj imovini, materijalnoj imovini, dugoročnim i kratkoročnim obvezama, prodaji, amortizaciji, profitabilnosti i dobiti prije kamata i poreza (EBIT). Ovaj postupak rezultirao je konačnim uzorkom od 19.818 poduzeća. Najveći broj poduzeća u uzorku čine mala poduzeća i ona koja se bave trgovinskom djelatnošću, što odražava i opću strukturu poduzeća prisutnih u ukupnoj gospodarskoj aktivnosti u Republici Hrvatskoj. Također, poduzeća koja posluju u trgovinskom sektoru zauzimaju najveći udio među malim, srednjim i velikim poduzećima, dok su vrlo velika poduzeća najčešće prisutna u prerađivačkom sektoru. Detaljnije informacije o ukupnom broju poduzeća po djelatnostima i veličini¹ dostupne su u Tablici 1.

¹ Velika poduzeća su sva poduzeća koja ne pripadaju skupini vrlo velikih poduzeća, što podrazumijeva da imaju ukupnu imovinu manju od 200 milijuna eura, manje od 1000 zaposlenih i poslovni prihod manji od 100 milijuna eura. Osim toga, moraju imati zadovoljen jedan od sljedećih uvjeta: poslovni prihod veći od 10 milijuna eura, ukupna imovina veća od 20 milijuna eura, ukupan broj

Tablica 1. Poduzeća u uzorku prema veličini i sektorskoj pripadnosti

	Mala	Srednja	Velika	Vrlo velika	Ukupno
Ukupan broj poduzeća	13.387 (100,0 %)	5.451 (100,0 %)	869 (100,0 %)	111 (100,0 %)	19.818 (100,0 %)
Građevinska djelatnost	3.032 (22,7 %)	1.190 (21,8 %)	110 (12,7 %)	8 (7,2 %)	4.340 (21,9 %)
Prerađivačka djelatnost	3.635 (27,1 %)	1.892 (34,7 %)	362 (41,7 %)	54 (48,7 %)	5.943 (30,0 %)
Trgovinska djelatnost	6.720 (50,2 %)	2.369 (43,5 %)	397 (45,6 %)	49 (44,1 %)	9.535 (48,1 %)

Izvor: izrada prema podacima baze podataka Orbis Europe

Istraživanje i analiza prikupljenih podataka temelje se na mikroekonomskim odrednicama, odnosno varijablama koje su specifične za svako pojedinačno poduzeće i za koje se pretpostavlja da utječu na držanje novca u poduzećima. Kao zavisna varijabla koja označava držanje novca uzet je omjer novca i novčanih ekvivalenata prema ukupnoj imovini (CASH). Kao potencijalne odrednice držanja novca razmatraju se sljedeće nezavisne varijable: profitabilnost (ROA), neto radni kapital (NWC), investicije (INV), mogućnost rasta (GROWTH), financijska poluga (LEV), vjerojatnost financijskih poteškoća (FDC), novčani tok (CFOR), rast BDP-a (GDP_g), starost (AGE), veličina (SIZE), pravni oblik (LEGAL) i sektor (SECTOR). U Tablici 2. prikazan je popis varijabli i način izračuna, dok se u Tablici 3. nalazi deskriptivna analiza korištenih varijabli, uz napomenu da su svi financijski omjeri podvrgnuti winsorizaciji².

Tablica 2. Opis varijabli korištenih u istraživanju

Simbol	Varijabla	Opis
CASH	Zadržavanje gotovine	Novac i novčani ekvivalenti / ukupna imovina
ROA	Profitabilnost	Neto dobit / ukupna imovina
NWC	Neto radni kapital	(Kratkotrajna imovina – kratkoročne obveze) / ukupna imovina
INV	Investicije	[(Materijalna imovina – materijalna imovina prethodnog razdoblja) + amortizacija] / ukupna imovina

zaposlenih 150. Ona poduzeća koja ne zadovoljavaju barem jedan od kriterija za velika poduzeća uključuju se u skupinu srednjih poduzeća. Mala poduzeća su sva ona poduzeća koja imaju poslovni prihod manji od milijun eura, ukupnu imovinu manju od 2 milijuna eura i manje od 15 zaposlenika (definicija veličine prema bazi podataka Orbis Europe razlikuje se od definicije Europske komisije).

² Za ograničavanje ekstremnih vrijednosti korišteno je winsoriziranje (engl. *winsorizing*) svih financijskih omjera na 1 i 99 percentil.

GROWTH	Mogućnost rasta	(Prodaja u tekućem razdoblju – prodaja u prethodnom razdoblju) / prodaja u prethodnom razdoblju
LEV	Financijska poluga	Ukupni dug / ukupna imovina
FDC	Vjerojatnost nastanka financijskih poteškoća	(Standardna devijacija – očekivana vrijednost EBIT-a) / ukupna imovina
CFOR	Novčani tok	(Poslovni rezultat razdoblja + amortizacija) / prihodi poslovne aktivnosti
AGE	Starost poduzeća	Trenutačna godina – godina osnutka poduzeća
SIZE	Veličina	Prirodni logaritam ukupne imovine
LEGAL	Pravni oblik	1 – dionička društva 2 – društva s ograničenom odgovornošću
SECTOR	Sektor	1 – građevinska djelatnost 2 – prerađivačka djelatnost 3 – trgovinska djelatnost
GDP_g	Rast BDP-a	Podaci sa stranice Svjetske banke (worldbank.org)

Izvor: izrada na temelju dostupnih podataka

Tablica 3. Deskriptivna statistika

UKUPAN BROJ PODUZEĆA (sve tri djelatnosti)								
	CASH	ROA	NWC	INV	GROWTH	LEV	FDC	AGE
Prosječna vrijednost	0,154	8,85	0,22	0,07	0,23	0,64	20,75	15,50
Medijan	0,08	5,75	0,26	0,02	0,06	0,59	6,78	14
Stand. dev.	0,18	17,3	0,45	0,13	0,84	0,44	38,82	10,88
Minimum	0,00	-50,68	-1,75	-0,21	-0,82	0,03	0,05	0
Maksimum	0,81	71,4	0,93	0,62	5,79	2,78	248,2	324
GRAĐEVINSKA DJELATNOST								
Prosječna vrijednost	0,164	10,24	0,19	0,10	0,43	0,653	11,35	12,55
Medijan	0,09	6,54	0,23	0,04	0,10	0,62	3,84	11
Stand. dev.	0,19	18,83	0,44	0,15	1,43	0,41	20,91	8,77
Minimum	0,00	-54,05	-1,6	-0,25	-0,92	0,04	0,04	0
Maksimum	0,81	74,14	0,91	0,67	10,30	2,67	131,2	121
PRERAĐIVAČKA DJELATNOST								
Prosječna vrijednost	0,138	8,08	0,20	0,081	0,19	0,60	19,13	16,55
Medijan	0,06	5,27	0,22	0,04	0,06	0,58	5,34	15
Stand. dev.	0,18	16,18	0,41	0,13	0,69	0,38	38,06	13,89
Minimum	0,00	-49,64	-1,47	-0,19	-0,08	0,03	0,03	0
Maksimum	0,78	66,49	0,91	0,63	4,65	2,35	241,2	324

TRGOVINSKA DJELATNOST								
Prosječna vrijednost	0,16	8,74	0,24	0,54	0,18	0,65	22,9	16,11
Medijan	0,09	5,78	0,31	0,02	0,05	0,6	8,18	17
Stand. dev.	0,19	17,2	0,49	0,11	0,7	0,48	41,2	9,22
Minimum	0,00	-49,72	-2,0	-0,2	-0,08	0,03	0,08	0
Maksimum	0,82	72,9	0,94	0,56	4,71	3,14	266,8	91

Izvor: izrada na temelju dobivenih rezultata

Iako postoje varijacije između poduzeća koja pripadaju različitim djelatnostima, u prosjeku, držanje novca (CASH) u svim poduzećima iznosilo je 15,4 % ili 15,4 eura na 100 eura imovine. Prosjek držanja novca u poduzećima građevinske (16,4 %) i trgovinske djelatnosti (15,9 %) bio je iznad općeg prosjeka, dok su poduzeća prerađivačke djelatnosti (13,8 %) u prosjeku zadržavala manje novca od ukupnog prosjeka.

Prosječni povrat na imovinu (ROA) bio je relativno visok po svim djelatnostima, što ukazuje na to da su poduzeća ostvarila visok povrat na imovinu. Prosječni radni kapital (NWC) u poduzećima svih triju djelatnosti bio je pozitivan, što sugerira da su sva poduzeća u mogućnosti podmiriti svoje kratkoročne obveze kratkotrajnom imovinom.

Prosječna zaduženost (LEV) svih poduzeća iznosila je 64 % ili 64 eura na svakih 100 eura imovine. Poduzeća građevinske (65,3 %) i trgovinske djelatnosti (65 %) u prosjeku su se više zaduživala, dok su poduzeća prerađivačke djelatnosti (60 %) u prosjeku zaduživala manje od ukupnog prosjeka.

Prosječna starost poduzeća kretala se oko 15,5 godina. Maksimalna starost poduzeća prerađivačke djelatnosti iznosila je 324 godine, dok je najstarije poduzeće građevinske djelatnosti poslovalo 121 godinu, a trgovinske djelatnosti 91 godinu.

4.2. METODOLOGIJA

Panel skup podataka odnosi se na skup koji prati određeni uzorak tijekom vremena, pružajući višestruka opažanja o svakoj jedinici promatranja unutar tog uzorka (Hsiao, 2014). Kod statične panel-analize u procjeni modela moguće je koristiti tri vrste procjenitelja, i to: 1) združeni procjenitelj (engl. *Pooled Ordinary Least Squares* – POLS) koji ima najviše ograničenja, ali može poslužiti

kao uvod u panel-analizu, 2) fiksni procjenitelj (engl. *Fixed Effects* – FE) i 3) slučajni procjenitelj (engl. *Random Effects* – RE).

U skladu s panel-analizom i odrednicama držanja novca prikazanim u Tablici 2., formulira se sljedeći model:

$$CASH_{it} = \beta_0 + \beta_1 ROA_{it} + \beta_2 NWC_{it} + \beta_3 INV_{it} + \beta_4 GROWTH_{it} + \beta_5 LEV_{it} + \beta_6 FDC_{it} + \beta_7 CFOR_{it} + \beta_8 GDP\_g_t + \beta_9 AGE_{it} + \beta_{10} \ln SIZE_{it} + \beta_{11} LEGAL_i + \beta_{12} SECTOR_i + \mu_i + \lambda_t + \varepsilon_{it} \quad (1)$$

Uz varijable navedene u Tablici 2., μ_i predstavlja neopažene karakteristike pojedinog poduzeća (kao što su obrazovanje i sposobnosti menadžmenta, zaposlenika, percepcije kupaca, odnosi s dobavljačima) koje su konstantne u vremenu i specifične za svako poduzeće. λ_t predstavlja vremenske *dummy* varijable koje se mijenjaju tijekom vremena, ali su iste za sva poduzeća u promatranom razdoblju, dok je greška relacije.

Na temelju rezultata Hausmanova testa (1978), izvršen je odabir između procjene modela s fiksnim i modela sa slučajnim efektom. Hausmanov test testira je li značajna razlika između procijenjenih parametara modela s fiksnim i slučajnim efektom. Oba procjenitelja bit će konzistentna ako ne postoji korelacija između individualnih karakteristika jedinica promatranja i nezavisnih varijabli (regresora). U slučaju velikih uzoraka, procjene parametara konvergirat će prema stvarnoj vrijednosti parametra β_K , što znači da se u tom slučaju procjene modela s fiksnim efektom neće bitno razlikovati od procjena modela sa slučajnim efektom. S obzirom na to da slučajni efekt ima manju varijancu, smatra se efikasnijim i primjenjuje se u takvim situacijama. Međutim, ako slučajna komponenta greške korelira s bilo kojom nezavisnom varijablom, procjenitelj slučajnog efekta postaje nekonzistentan, dok je procjenitelj fiksnog efekta i dalje konzistentan. Razlike između procijenjenih parametara ovih dvaju modela bit će značajne u situacijama gdje postoji korelacija između varijabli x_{it} i individualnih efekata α_i . U takvim slučajevima primjenjuje se model s fiksnim efektom.

5. REZULTATI ISTRAŽIVANJA

U nastavku je prikazan utjecaj odrednica držanja novca primjenom statičke panel-analize. Provedena je analiza na uzorku od 19.818 poduzeća u djelatno-

sti trgovine, prerađivačke industrije i građevinske djelatnosti u razdoblju od 2016. do 2021. godine.³

U Tablici 4. prikazan je utjecaj poduzeću specifičnih obilježja na držanje novca izraženog kao omjer novca i novčanih ekvivalenata prema ukupnoj imovini (CASH). Navedeni modeli procijenjeni su uzimajući u obzir sva poduzeća iz promatranih djelatnosti primjenom združenog procjenitelja (POLS), procjenitelja s fiksnim efektom (FE) i procjenitelja sa slučajnim efektom (RE).

Tablica 4. Determinante držanja novca svih poduzeća u RH (združeni model – POLS, model s fiksnim učinkom – FE, model sa slučajnim efektom – RE)

Varijable	(1)	(2)	(3)
CASH – zavisna varijabla	POLS	RE	FE
ROA	0,002*** [32,61] (0,000)	0,001*** [24,631] (0,000)	0,001*** [19,760] (0,000)
CFOR	0,000 [1,425] (0,000)	-0,000 [-0,449] (0,000)	-0,000 [-1,379] (0,000)
NWC	0,124*** [36,601] (0,003)	0,141*** [39,702] (0,004)	0,144*** [28,187] (0,005)
INV	-0,068*** [-14,567] (0,005)	-0,068*** [-18,467] (0,004)	-0,071*** [-16,924] (0,004)
GROWTH	0,000 [0,263] (0,001)	0,005*** [7,071] (0,001)	0,006*** [8,494] (0,001)
LEV	0,009** [2,572] (0,004)	0,040*** [10,296] (0,004)	0,076*** [12,635] (0,006)
FDC	0,001*** [17,456] (0,000)	0,001*** [10,579] (0,000)	0,000*** [3,715] (0,000)
Age	0,001*** [5,134] (0,000)	0,001*** [12,724] (0,000)	0,009*** [25,495] (0,000)

³ Prethodno je ispitana korelacija između nezavisnih varijabli s obzirom na to da multikolinearnost može dovesti do netočnih zaključaka o značajnosti pojedinih varijabli. Svi koeficijenti korelacije između promatranih parova varijabli niži su od 0,7, što omogućuje daljnju empirijsku analizu s danim setom varijabli.

LSIZE	-0,012*** [-15,286] (0,001)	-0,011*** [-11,917] (0,001)	-0,005* [-1,860] (0,003)
GDP_g	0,000*** [2,579] (0,000)	0,000* [1,865] (0,000)	-0,000*** [-5,200] (0,000)
Legal (d.o.o.)	0,012* [1,788] (0,007)	0,055*** [7,114] (0,008)	
Sector (manufacturing)	-0,013*** [-4,261] (0,003)	-0,019*** [-6,217] (0,003)	
Sector (trade)	-0,009*** [-3,301] (0,003)	-0,016*** [-5,601] (0,003)	
Konstanta	0,149*** [14,321] (0,010)	0,081*** [7,009] (0,012)	-0,056*** [-3,517] (0,016)
Broj opažanja	76.484	76.484	76.484
Broj poduzeća	19.818	19.818	19.818
Koeficijent determinacije -R2	0,198		
Hausmanov test (vrijednost chi-square)		2.298,39***	

Napomena: statistička signifikantnost (p-vrijednost): *** $p < 0,01$, ** $p < 0,05$, * $p < 0,1$; t-statistika u uglatim zagradama, robusne standardne pogreške u okruglim zagradama

Rezultati Hausmanova testa ukazuju na značajnu razliku između procijenjenih parametara modela s fiksnim efektom (FE) i modela sa slučajnim efektom (RE) (vrijednost chi-square statistike 2.298,39), što implicira postojanje korelacije između individualnih karakteristika jedinica promatranja i nezavisnih varijabli. U prisutnosti takve korelacije, procjenitelj s fiksnim efektom ostaje konzistentan, što čini rezultate dobivene ovim procjeniteljem relevantnima. Dodatno, opravdanost korištenja modela s fiksnim efektom (FE) potvrđena je i u usporedbi sa združenim modelom (POLS), jer je vrijednost F-testa iznosila 9,99 (značajno na razini od 5 % signifikantnosti). Slijedom toga, odbacuje se nulta hipoteza koja pretpostavlja da su fiksni efekti svih promatranih jedinica jednaki međusobno, sugerirajući da promatrane jedinice nemaju jednak zajednički konstantni član. Stoga je prikladnije koristiti procjenitelj s fiksnim efektom (FE) u odnosu na združeni procjenitelj (POLS).

Primjenom Whiteova testa utvrđeno je prisustvo heteroskedastičnosti u analiziranim modelima (vrijednost chi-square statistike iznosi 9.770,45, p-vrijednost $> 0,05$), te su u tablici prikazani modeli s korigiranim standardnim pogreškama parametara (engl. *White's Heteroscedasticity-corrected variances and standard errors*).

Sve odrednice, osim novčanog toka, su značajno povezane s držanjem novca u poduzećima. Zaključci će biti temeljeni na osnovi procjene modela s fiksnim procjeniteljem s obzirom na to da je Hausmanovim testom utvrđena prikladnost procjene modela preko navedenog procjenitelja.

Postoji pozitivna povezanost između profitabilnosti i novca u poduzećima, što je u skladu s prethodnim istraživanjima (Aftab *et al.*, 2018; Al Najjar i Belghitar, 2011; Sethi i Swain, 2019; Arfan *et al.*, 2017) koja sugeriraju da profitabilnija poduzeća drže više novca. Također, kao i u ranijim istraživanjima (Sethi i Swain, 2019), potvrđena je pozitivna veza neto radnog kapitala s držanjem novca, što znači da poduzeća s većim neto radnim kapitalom drže više novca, odnosno brže transformiraju radni kapital u gotovinu. Investicije su negativno povezane s držanjem novca, što je u skladu s rezultatima Kwan i Lau (2020), sugerirajući da poduzeća s većim kapitalnim izdacima drže manje gotovine. Potvrđena je i pozitivna povezanost između rasta poduzeća i držanja novca, što se može objasniti potrebom za financiranjem većeg rasta prodaje u skladu s prethodnim istraživanjima (Aftab *et al.*, 2018; Kwan i Lau, 2020; Al Najjar i Belghitar, 2011; Garcia-Teruel i Solano, 2008; Opler *et al.*, 1999; Sethi i Swain, 2019; Arfan *et al.*, 2017). Nadalje, potvrđena je pozitivna veza između financijske poluge i izloženosti financijskom riziku s držanjem novca unutar poduzeća. Ovi rezultati su u skladu s prethodnim istraživanjima (Kwan i Lau, 2020; Al Najjar i Belghitar, 2011; Garcia-Teruel i Solano, 2008; Sethi i Swain, 2019), sugerirajući da će poduzeća koja koriste višu financijsku polugu imati tendenciju većeg držanja novca. Ova povezanost može se objasniti time da se kod zaduženijih poduzeća očekuju financijski problemi, pa stoga preferiraju držanje novca kako bi smanjili vjerojatnost financijskih poteškoća. Starija poduzeća zadržavaju više gotovine, što se poklapa s rezultatima istraživanja (Hussain *et al.*, 2020), sugerirajući da su iskusnija poduzeća svjesnija rizika poslovanja i stoga drže više novca. Veličina poduzeća ima značajan utjecaj na držanje novca na razini značajnosti od 10 % (fiksni model). Rezultati su u skladu s brojnim istraživanjima (Garcia-Teruel i Solano, 2008; Opler *et al.*, 1999; Martinez-Sola *et al.*, 2011; Sethi i Swain, 2019; Dittmar *et al.*, 2003) koja predviđaju negativnu povezanost između veličine poduzeća i držanja novca, sugerirajući da manja

poduzeća imaju tendenciju držanja novca zbog otežanog pristupa vanjskom financiranju.

Rast BDP-a, kao varijabla iz okruženja je negativno povezana s držanjem novca, što je potvrđeno i u prethodnim istraživanjima (Garcia-Teruel i Solano, 2008; Chen *et al.*, 2016), koja zaključuju da će poduzeća držati manje novca u fazi ekonomske ekspanzije.

Razlike u držanju novca s obzirom na pravni oblik poduzeća i pripadnost pojedinoj djelatnosti nije mogao biti procijenjen s obzirom na to da se radi o varijablama koje su konstantne u vremenu. Naime, fiksni procjenitelj (FE) određenim transformacijama izbacuje varijable koje su konstantne u vremenu. Ipak, analiza združenog modela (POLS) i modela sa slučajnim učinkom (RE) pokazuje značajne razlike u zadržavanju gotovine ovisno o pravnom obliku poduzeća i djelatnosti kojoj poduzeće pripada. Društva s ograničenom odgovornošću drže više novca u odnosu na dionička društva. Također, razlike postoje između poduzeća u različitim djelatnostima, pri čemu poduzeća u prerađivačkoj i trgovinskoj djelatnosti drže manje novca u odnosu na građevinska poduzeća.

U nastavku su prikazane procjene modela s fiksnim efektom uzimajući u obzir veličinu poduzeća kako bi se ispitalo postoje li razlike u odrednicama držanja gotovine s obzirom na kategoriju veličine poduzeća prema Orbis Europe bazi (Tablica 5.). Prvi stupac prikazuje analizu za poduzeća koja pripadaju u skupinu malih i srednjih poduzeća (SM), dok se drugi stupac odnosi na rezultate analize provedene na skupini velikih i vrlo velikih poduzeća (LVL). Hausmanov test u svim je modelima potvrdio da je fiksni procjenitelj jedini konzistentan i kao takav prikladan za daljnju analizu.

Tablica 5. Prikaz rezultata analize modela s fiksnim efektom s obzirom na kategorije veličine poduzeća

Variable	(1)	(2)
CASH – zavisna varijabla	FE_SM	FE_IVL
ROA	0,001***	0,000
	[19,901]	[0,481]
	(0,000)	(0,000)
CFOR	-0,000	0,001
	[-1,557]	[1,603]
	(0,000)	(0,000)
NWC	0,144***	0,156***
	[27,034]	[9,465]
	(0,005)	(0,017)
INV	-0,072***	-0,042***
	[-16,716]	[-3,140]
	(0,004)	(0,013)
GROWTH	0,006***	0,000
	[8,544]	[0,059]
	(0,001)	(0,003)
LEV	0,078***	0,019
	[12,573]	[0,995]
	(0,006)	(0,019)
FDC	0,000***	-0,002
	[3,501]	[-0,113]
	(0,000)	(0,020)
Age	0,010***	0,006***
	[24,699]	[6,904]
	(0,000)	(0,001)
LSIZE	-0,006**	0,001
	[-1,993]	[0,118]
	(0,003)	(0,011)
GDP_g	-0,000***	-0,000**
	[-4,832]	[-2,324]
	(0,000)	(0,000)
Konstanta	-0,049***	-0,125
	[-3,071]	[-1,282]
	(0,016)	(0,097)
Broj opažanja	71.898	4.586
Broj poduzeća	18.838	980
Hausmanov test (vrijednost chi-square)	2.124,69***	166,18***

Napomena: statistička signifikantnost (p-vrijednost): *** $p < 0,01$, ** $p < 0,05$, * $p < 0,1$; t-statistika u uglatim zagradama, robusne standardne pogreške u okruglim zagradama

Kada se analizira držanje novca u malim i srednjim poduzećima, primjećuje se da su sve odrednice značajne, osim novčanog toka u odnosu na ostvarene prihode. Pozitivna veza profitabilnosti i neto radnog kapitala s držanjem novca sugerira da će profitabilnija mala i srednja poduzeća te ona s većim radnim kapitalom držati više sredstva na transakcijskim računima. Takva poduzeća bit će sposobna podmirivati sve troškove, ostavljajući dio novca unutar poduzeća kako bi lakše prevladala eventualne poteškoće u budućem poslovanju. Investicije su negativno povezane s držanjem novca, što znači da će mala i srednja poduzeća koja više investiraju imati manje novca na računima. Nadalje, više novca držat će mala i srednja poduzeća koja imaju veće mogućnosti rasta, zaduženija poduzeća, ona koja su izložena većem financijskom riziku te starija, odnosno iskusnija poduzeća. Očekivano, manja poduzeća unutar ove skupine držat će više novca na računima. U konačnici, povoljan ekonomski rast djeluje na smanjenje držanja novca u ovoj skupini poduzeća.

Kod skupine velikih i vrlo velikih poduzeća, na držanje novca značajno utječu samo četiri varijable: neto radni kapital, investicije, starost poduzeća i rast BDP-a. Starost poduzeća i neto radni kapital pozitivno utječu na držanje novca u velikim i vrlo velikim poduzećima, sugerirajući da će starija poduzeća u okviru te skupine i ona s višim neto radnim kapitalom držati više novca na računima. S druge strane, investicije i ekonomski rast imaju negativan utjecaj na držanje novca. To ukazuje na to da će spomenuta poduzeća držati manje novca ako više ulažu u dugotrajnu imovinu i ako je prisutan ekonomski rast.

Analiza dviju kategorija poduzeća – malih i srednjih te velikih i vrlo velikih – otkriva značajne razlike u utjecaju odabranih čimbenika na držanje novca. Četiri odrednice (neto radni kapital, starost poduzeća, investicije i rast BDP-a) značajno utječu na držanje novca u objema kategorijama. Neto radni kapital i starost poduzeća imaju pozitivan utjecaj, dok investicije i rast BDP-a imaju negativan utjecaj. Osim toga, na držanje novca u skupini malih i srednjih poduzeća značajno je dodatnih pet odrednica: profitabilnost, mogućnost rasta, zaduženost (financijska poluga), financijski rizik i veličina poduzeća. Dakle, veličina poduzeća pokazala se značajnom samo za skupinu malih i srednjih poduzeća, dok kod velikih i vrlo velikih poduzeća ne postoje značajne razlike u držanju novca.

Rezultati analize provedene zasebno za poduzeća građevinske, prerađivačke i trgovinske djelatnosti prezentirani su u Tablici 6.

Tablica 6. Odrednice držanja novca s obzirom na djelatnost poduzeća (FE – model s fiksnim efektom)

Varijable	(1)	(2)	(3)
CASH – zavisna varijabla	Građevinska djelatnost	Prerađivačka djelatnost	Trgovinska djelatnost
ROA	0,001***	0,001***	0,001***
	[10,922]	[9,784]	[13,405]
	(0,000)	(0,000)	(0,000)
CFOR	-0,000	-0,000	-0,000
	[-0,487]	[-1,373]	[-0,438]
	(0,000)	(0,000)	(0,000)
NWC	0,162***	0,162***	0,127***
	[15,148]	[18,581]	[16,845]
	(0,011)	(0,009)	(0,008)
INV	-0,053***	-0,051***	-0,098***
	[-5,982]	[-7,674]	[-14,857]
	(0,009)	(0,007)	(0,007)
GROWTH	0,005***	0,005***	0,006***
	[4,878]	[3,315]	[5,340]
	(0,001)	(0,002)	(0,001)
LEV	0,010***	0,071***	0,069***
	[7,560]	[7,009]	[8,133]
	(0,013)	(0,010)	(0,009)
FDC	0,000	0,000**	0,000***
	[0,952]	[2,322]	[2,913]
	(0,000)	(0,000)	(0,000)
Age	0,010***	0,009***	0,010***
	[9,698]	[14,802]	[18,593]
	(0,001)	(0,001)	(0,001)
LSIZE	-0,008	-0,007	-0,002
	[-1,328]	[-1,568]	[-0,608]
	(0,006)	(0,005)	(0,004)
GDP_g	-0,001***	-0,000**	-0,000**
	[-4,296]	[-2,229]	[-2,377]
	(0,000)	(0,000)	(0,000)
Konstanta	-0,020	-0,056**	-0,071***
	[-0,608]	[-2,012]	[-3,046]
	(0,033)	(0,028)	(0,023)
Broj opažanja	15,489	23,270	37,725
Broj poduzeća	4.340	5.943	9.535
Hausmanov test (vrijednost chi-square)	428,74***	787,67***	1.169,78***

Napomena: statistička signifikantnost (p-vrijednost): *** $p < 0,01$, ** $p < 0,05$, * $p < 0,1$; t-statistika u uglatim zagradama, robusne standardne pogreške u okruglim zagradama

Na temelju dobivenih rezultata može se zaključiti kako postoje sličnosti u držanju novca s obzirom na djelatnost poduzeća.

Sve odrednice, osim novčanog toka, financijskog rizika i veličine poduzeća, imaju značajan utjecaj na držanje novca u poduzećima građevinske djelatnosti. Pozitivan utjecaj imaju povrat na imovinu i neto radni kapital, odnosno profitabilnija poduzeća i ona s višim neto radnim kapitalom držat će više novca, što ovim poduzećima omogućuje lakše podmirenje troškova i jačanje financijskog stanja. Zatim, poduzeća koja više investiraju držat će manje novca, što je očekivano jer su ta sredstva usmjerena prema dugotrajnoj imovini. S druge strane, poduzeća s većim mogućnostima rasta držat će više novca na računima, što može poslužiti kao podrška rastućoj prodaji. Povećanje zaduženosti također dovodi do povećanja držanja novca, što može biti strategija za smanjenje vjerojatnosti od insolventnosti s obzirom na to da su takva poduzeća izložena financijskom riziku. Starija poduzeća u građevinskom sektoru drže više novca, što može odražavati njihovo dugotrajno iskustvo u poslovanju i oprezniji pristup financijskim strategijama. Konačno, makroekonomska situacija, izražena rastom BDP-a, pokazuje da će građevinska poduzeća držati manje novca u povoljnim makroekonomskim uvjetima.

U slučaju poduzeća prerađivačke djelatnosti, značajne su sve varijable izuzev novčanog toka i veličine poduzeća. Također, pozitivan utjecaj na držanje novca imaju povrat na imovinu i neto radni kapital. Investiranje, mogućnost rasta, zaduženost i starost poduzeća također pokazuju slične obrasce kao u građevinskoj djelatnosti. Također, prerađivačka poduzeća s volatilnijom dobiti (FDC) drže više novca na računima, što se može pripisati većoj nesigurnosti u njihovu poslovanju.

Slično kao i kod poduzeća prerađivačke djelatnosti, utvrđeno je da sve odrednice, osim novčanog toka i veličine poduzeća, značajno utječu na držanje novca kod poduzeća koja se bave trgovinskom djelatnošću. Povrat na imovinu i neto radni kapital pokazuju pozitivan utjecaj, dok investicije, mogućnost rasta i zaduženost slijede slične obrasce kao u prethodnim djelatnostima. Starost poduzeća ima pozitivan utjecaj na držanje novca, dok makroekonomska varijabla – rast BDP-a, ima negativan utjecaj.

U Tablici 7. prikazani su rezultati modela s fiksnim efektom, pri čemu su podaci razdvojeni prema veličini poduzeća i djelatnosti. Prvi model prikazuje odrednice držanja novca u malim i srednjim poduzećima građevinske djelatnosti, dok drugi model obuhvaća velika i vrlo velika poduzeća iste djelatnosti. Treći i četvrti model analiziraju mala i srednja, odnosno velika i vrlo velika

poduzeća prerađivačke djelatnosti. Posljednja dva stupca posvećena su trgovinskoj djelatnosti, prikazujući utjecaj odrednica u malim i srednjim te velikim i vrlo velikim poduzećima.

Tablica 7. Prikaz rezultata analize modela s fiksnim efektom s obzirom na veličinu poduzeća po različitim djelatnostima

Varijable	(1)	(2)	(3)	(4)	(5)	(6)
CASH zav. var.	Građevinska SM	Građevinska LVL	Prerađivačka SM	Prerađivačka LVL	Trgovinska SM	Trgovinska LVL
ROA	0,001***	0,001	0,001***	0,001***	0,001***	-0,000
	[10,837]	[0,967]	[9,710]	[2,592]	[13,783]	[-0,744]
	(0,000)	(0,001)	(0,000)	(0,000)	(0,000)	(0,001)
CFOR	-0,000	-0,000	-0,000	0,000	-0,000	0,002*
	[-0,421]	[-0,181]	[-1,446]	[0,455]	[-0,756]	[1,858]
	(0,000)	(0,0001)	(0,000)	(0,000)	(0,000)	(0,001)
NWC	0,161***	0,189***	0,162***	0,152***	0,126***	0,142***
	[14,727]	[3,803]	[17,633]	[6,697]	[16,102]	[5,910]
	(0,011)	(0,050)	(0,009)	(0,022)	(0,008)	(0,024)
INV	-0,054***	0,018	-0,053***	-0,018	-0,099***	-0,092***
	[-6,027]	[0,343]	[-7,567]	[-1,075]	[-14,597]	[-4,107]
	(0,009)	(0,053)	(0,007)	(0,017)	(0,007)	(0,022)
GROWTH	0,005***	0,000	0,005***	-0,013***	0,006***	0,008
	[4,923]	[0,038]	[3,477]	[-2,705]	[5,319]	[1,063]
	(0,001)	(0,002)	(0,002)	(0,005)	(0,001)	(0,007)
LEV	0,010***	0,112	0,073***	0,057***	0,073***	-0,041
	[7,452]	[1,544]	[6,733]	[3,026]	[8,261]	[-1,257]
	(0,013)	(0,072)	(0,012)	(0,019)	(0,009)	(0,033)
FDC	0,000	-0,103	0,000**	0,081**	0,000***	-0,017
	[0,945]	[-1,048]	[2,113]	[2,008]	[2,753]	[-0,717]
	(0,000)	(0,098)	(0,000)	(0,040)	(0,000)	(0,024)
Age	0,010***	0,011***	0,010***	0,006***	0,010***	0,006***
	[9,310]	[3,991]	[14,286]	[5,594]	[18,171]	[3,571]
	(0,001)	(0,003)	(0,001)	(0,001)	(0,001)	(0,002)
LSIZE	-0,008	-0,033	-0,009*	0,019	-0,003	-0,005
	[-1,261]	[-1,297]	[-1,799]	[1,537]	[-0,709]	[-0,266]
	(0,007)	(0,025)	(0,005)	(0,012)	(0,004)	(0,017)
GDP_g	-0,001***	-0,001**	-0,000	-0,001***	-0,000**	0,000
	[-4,109]	[-2,265]	[-1,598]	[-3,126]	[-2,460]	[0,359]
	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
Konstanta	-0,0167	0,083	-0,041	-0,383***	-0,068***	0,032
	[-0,503]	[0,366]	[-1,450]	[-3,087]	[-2,924]	[0,210]
	(0,034)	(0,227)	(0,028)	(0,124)	(0,023)	(0,154)

Br. opaž.	14.934	555	21.297	1.973	35.667	2.058
Br. poduzeća	4.222	118	5.527	416	9.089	446
Hausmanov test (chi-square)	410,08***	40,54***	702,88***	99,17***	1.114***	76,47***

Napomena: statistička signifikantnost (p-vrijednost): *** $p < 0,01$, ** $p < 0,05$, * $p < 0,1$; t-statistika u uglatim zagrada, robusne standardne pogreške u okruglim zagrada

Rezultati sugeriraju da postoje razlike u odrednicama držanja novca, uzimajući istodobno u obzir veličinu i sektorsku pripadnost poduzeća.

U malim i srednjim (MS) poduzećima građevinske djelatnosti, sve varijable, osim novčanog toka, financijskog rizika i veličine poduzeća, utječu na držanje novca (Model 1). Profitabilnija MS građevinska poduzeća te ona s višim neto radnim kapitalom i mogućnošću rasta intenzivnije drže novac. Isto vrijedi za zaduženija poduzeća u okviru promatrane skupine poduzeća. Poduzeća s većom mogućnošću za investiranje drže manje novca. Poduzeća s dužim poslovanjem i iskustvom više drže novca na računima. Što se tiče makroekonomske situacije, povećanje BDP-a rezultira smanjenjem držanja novca u malim i srednjim poduzećima građevinske djelatnosti. Veličina poduzeća nije ključan faktor u držanju novca, sugerirajući da nema značajnih razlika između MS građevinskih poduzeća s obzirom na njihovu veličinu.

U pogledu velikih i vrlo velikih poduzeća građevinske djelatnosti (Model 2), ključan faktori su neto radni kapital, starost poduzeća i ekonomski rast mjeren rastom BDP-a. Velika i vrlo velika poduzeća s većim neto radnim kapitalom imaju veću tendenciju držanja novca na računima. Slično prethodnoj skupini, poduzeća s duljim poslovnim stažem često drže više novca. Utjecaj makroekonomske varijable je negativan, što znači da povećanje BDP-a dovodi do smanjenja držanja novca. Također, nema značajnih razlika u držanju novca kada se promatra veličina poduzeća unutar kategorije velikih i vrlo velikih poduzeća u građevinskoj djelatnosti.

Kada se analiziraju mala i srednja poduzeća u prerađivačkoj industriji prema Modelu 3, sve varijable, osim novčanog toka i rasta BDP-a, značajno utječu na držanje novca. Poduzeća s većim povratom na imovinu i neto radnim kapitalom te zaduženija poduzeća drže više novca na računima. Ona koja više ulažu u dugotrajnu materijalnu imovinu drže manje novca, dok brže rastuća mala i srednja poduzeća u prerađivačkoj industriji, slično kao i u građevinskom sektoru, drže više novca. Za razliku od građevinskih poduzeća, financijski rizik pozitivno utječe na držanje novca u malim i srednjim poduzećima prerađivačke industrije, što znači da ta poduzeća često drže više novca kako bi se zaštitila

od mogućih financijskih izazova. Starija i iskusnija poduzeća drže više novca u odnosu na mlađa poduzeća. U suprotnosti s malim i srednjim poduzećima u građevinskoj djelatnosti, kod prerađivačke industrije postoji razlika u držanju novca prema veličini poduzeća, gdje manja poduzeća drže više novca od većih poduzeća unutar iste skupine.

Za velika i vrlo velika poduzeća u prerađivačkoj industriji (Model 4), za razliku od građevinske djelatnosti, sve varijable, osim novčanog toka, investicija i veličine poduzeća, značajno utječu na držanje novca. Velika i vrlo velika poduzeća s većim povratom na imovinu i neto radnim kapitalom drže više novca. Ako poduzeća ove skupine imaju veće mogućnosti za rast, držat će manje novca na računima, što se razlikuje od drugih skupina, gdje brže rastuća poduzeća drže više novca. Slično kao i kod prethodnih skupina, zaduženija poduzeća drže više novca, a isto vrijedi i za poduzeća koja su izložena većem financijskom riziku i za ona s duljim poslovnim stažem. U razdoblju ekonomske ekspanzije drže manje novca, slično kao i ostale skupine poduzeća. Za razliku od malih i srednjih prerađivačkih poduzeća, ne postoje značajne razlike u držanju novca između poduzeća različite veličine u skupini velikih i vrlo velikih prerađivačkih poduzeća.

Posljednja skupina obuhvaća poduzeća u trgovinskoj djelatnosti (Modeli 5 i 6). Primjećuje se da sve odrednice, osim novčanog toka i veličine poduzeća, značajno utječu na držanje novca u skupini malih i srednjih poduzeća. Poduzeća s većim povratom na imovinu, višim neto radnim kapitalom, izraženijim mogućnostima rasta, zaduženija i više izložena financijskom riziku te duljim poslovnim stažem imaju veću tendenciju držanja novca na računima. Suprotno tome, veće investicije i ekonomski rast imaju negativan utjecaj na držanje novca u ovoj skupini poduzeća. Rezultati također ukazuju na to da nema značajnih razlika u držanju novca između malih i srednjih poduzeća unutar trgovinske djelatnosti.

Kod velikih i vrlo velikih poduzeća u trgovinskoj djelatnosti, na držanje novca značajno utječu neto radni kapital, investicije i starost poduzeća. Poduzeća s većim neto radnim kapitalom drže više novca, dok ona koja više investiraju drže manje novca na računima. Za razliku od ostalih skupina poduzeća, uz 10 % signifikantnosti, novčani tok ima značajan i pozitivan utjecaj na držanje novca u velikim i vrlo velikim trgovinskim poduzećima, odnosno poduzeća s višim novčanim tokovima drže više novca. Kao i u prethodnim skupinama, starija i iskusnija poduzeća drže više novca na računima. Važno je napomenuti da veličina poduzeća nije značajan faktor, što implicira da nema bitnih razlika

u držanju novca između velikih i vrlo velikih poduzeća različitih veličina unutar trgovinske djelatnosti.

6. ZAKLJUČAK

U istraživanju je analiziran utjecaj odrednica na držanje novca na uzorku od 19.818 poduzeća koja djeluju u Republici Hrvatskoj u razdoblju od 2016. do 2021. godine. Analiza obuhvaća poduzeća iz djelatnosti trgovine, građevinarstva i prerađivačke industrije, pri čemu su dodatno klasificirana prema veličini kao mala i srednja te velika i vrlo velika poduzeća. U skladu s prethodnim istraživanjima, analiziran je utjecaj različitih odrednica, uključujući profitabilnost, novčane tokove, neto radni kapital, investicije, rast poduzeća, financijsku polugu, vjerojatnost financijskih poteškoća, starost, veličinu, djelatnost i rast BDP-a. U analizi su korištene metode statičke panel-analize podataka, pri čemu se procjenitelj s fiksnim efektom pokazao kao najprikladniji procjenitelj.

Cilj rada jest ispitivanje varijacija u utjecaju navedenih odrednica na držanje novca u poduzećima, uzimajući u obzir djelatnost i veličinu poduzeća. Ovo predstavlja ključan doprinos rada jer dosadašnja istraživanja nisu istraživala razlike u utjecaju odrednica s obzirom na veličinu i djelatnost poduzeća.

Utvrđeno je da neto radni kapital pozitivno utječe na držanje novca u poduzećima, bez obzira na njihovu djelatnost i veličinu. Ovo potvrđuje pretpostavku da poduzeća s kraćim ciklusom konverzije gotovine imaju sposobnost brže transformacije radnog kapitala u gotovinu, što rezultira držanjem većeg iznosa novca u tim poduzećima. Također, utvrđeno je da povrat na imovinu ima pozitivan utjecaj kod svih malih i srednjih poduzeća, dok je kod skupine velikih i vrlo velikih poduzeća ova odrednica značajna samo za prerađivačka poduzeća. Potencijal rasta poduzeća pozitivno utječe na držanje novca u svim malim i srednjim poduzećima, dok je kod velikih i vrlo velikih poduzeća prerađivačke djelatnosti zabilježen negativan utjecaj. Ovo se može objasniti time što brzorastuća poduzeća često drže veće iznose novca kako bi financirala svoj rast i proširenje poslovanja. S druge strane, investiranje ima negativan utjecaj na držanje novca kod svih skupina poduzeća, osim kod velikih i vrlo velikih poduzeća građevinske i prerađivačke djelatnosti gdje izostaje značajan utjecaj ove odrednice. Očekivano je da će se razina novca smanjivati s povećanjem investicijske aktivnosti, što se potvrđuje u analizi. Zaduženost poduzeća značajno i pozitivno utječe na razinu novca u svim promatranim poduzećima, osim kod

velikih i vrlo velikih poduzeća građevinske i trgovinske djelatnosti. Zaduženija poduzeća preferiraju držanje novca kako bi smanjila vjerojatnost financijskih poteškoća. Slijedom navedenog, financijski rizik ima značajan i istosmjerni utjecaj na držanje novca kod poduzeća prerađivačke industrije za obje kategorije veličine, te kod skupine malih i srednjih poduzeća u trgovinskoj djelatnosti. Ovo potvrđuje da poduzeća s većom volatilnošću zarada drže više novca kako bi se pripremila na moguće poteškoće u poslovanju. Navedeni rezultati potvrđuju da zaduženost i financijski rizik poduzeća značajno utječu na razinu novca u poduzeću. Analizom nisu potvrđene značajne razlike u držanju novca s obzirom na veličinu poduzeća. Veličina poduzeća ima značajnu ulogu samo u kontekstu malih i srednjih poduzeća prerađivačke djelatnosti, pri čemu manja poduzeća zadržavaju više novca od većih unutar iste kategorije poduzeća prerađivačke djelatnosti, a to je uočeno na razini signifikantnosti od 10 %. Značajan je i utjecaj makroekonomske situacije na držanje novca u poduzećima. Rast BDP-a značajna je odrednica u svim kategorijama poduzeća, osim za mala i srednja poduzeća prerađivačke djelatnosti te velika i vrlo velika poduzeća trgovinske djelatnosti. U uvjetima loše makroekonomske situacije, poduzeća su sklonija zadržavanju novca kako bi se zaštitila od mogućih problema unutar poduzeća i kako bi vlasnici izbjegli gubitke.

Konačno, rezultati ukazuju na značajne razlike u odrednicama držanja novca promatrano po kategorijama veličine poduzeća, dok analiza na razini djelatnosti poduzeća ne ukazuje na značajne razlike u odrednicama držanja novca. Ovim istraživanjem ispitane su značajne odrednice držanja novca u poduzećima primjenom statične panel-analize. Preporuka za buduća istraživanja jest provesti analizu primjenom dinamičkih panel-modela kako bi se proširile spoznaje o navedenoj tematici. Nadalje, sugerira se proširenje obuhvata poduzeća na države srednje i istočne Europe kako bi se izvršila komparativna analiza i istražile potencijalne razlike u odrednicama držanja novca s obzirom na uvjete poslovanja u pojedinim državama.

REFERENCE

1. Aftab, U., Javid A. i Akhter, W. (2018) The Determinants of Cash Holdings around Different Regions of the World. *Business & Economic Review*, Vol. 10, No. 2, str. 151-182, online: <https://doi.org/10.22547/BER/10.2.7>
2. Ali, A. i Yousaf, S. (2013) Determinants of Cash holding in German Market. *IOSR Journal of Business and Management (IOSR-JBM)*, Vol. 12, No. 6, str. 28-34, online: <http://iosrjournals.org/iosr-jbm/papers/Vol12-issue6/D01262834.pdf>

3. Al-Najjar, B. i Belghitar, Y. (2011) Corporate Cash Holdings and Dividend Payments: Evidence from Simultaneous Analysis. *Managerial and Decision Economics*, Vol. 32, No. 4, str. 231-241, online: <https://doi.org/10.1002/mde.1529>
4. Al-Najjar, B. (2013) The financial determinants of corporate cash holdings: Evidence from some emerging markets. *International Business Review*, Vol. 22, No. 1, str. 77-88, online: <https://doi.org/10.1016/j.ibusrev.2012.02.004>
5. Arfan, M., Basir, H., Handayani, Majif, M., Fahlevi, H. i Dianah, A. (2017) Determinants of Cash Holding of Listed Manufacturing Companies in the Indonesian Stock Exchange. *DLSU Business & Economics Review*, Vol. 26, No. 2, str. 1-12, online: <https://doi.org/10.47312/aifer.v7i01.391>
6. Batuman, B., Yildiz, Y. i Baha Karan, M. (2022) The impact of the global financial crisis on corporate cash holdings: Evidence from Eastern European countries. *Borsa Istanbul Review*, Vol. 22, No. 4, str. 678-687, online: <https://doi.org/10.1016/j.bir.2021.10.002>
7. Chen, J., Tingting Jia, Z. i Sun, P. (2016) Real option component of cash holdings, business cycle, and stock returns. *International Review of Financial Analysis*, Vol. 45, str. 97-106, online: <https://doi.org/10.1016/j.irfa.2016.03.008>
8. Dittmar, A., Mahrt-Smith, J. i Servaes, H. (2003) International Corporate Governance and Corporate Cash Holdings. *The Journal of Financial and Quantitative Analysis*, Vol. 38, No. 1, str. 111-133, online: <https://www.jstor.org/stable/4126766>
9. Ferreira, M. i Vilela A. (2004) Why Do Firms Hold Cash? Evidence from EMU Countries. *European Financial Management*, Vol. 10, No. 2, str. 295-319, online: <https://doi.org/10.1111/j.1354-7798.2004.00251.x>
10. Garcia-Teruel, P. i Martinez-Solano, P. (2008) On the Determinants of SME Cash Holdings: Evidence from Spain. *Journal of Business Finance & Accounting*, Vol. 35, No. 1&2, str. 127-149, online: <https://doi.org/10.1111/j.1468-5957.2007.02022.x>
11. Guney, Y., Ozkan, A. i Ozkan, N. (2003) Additional international evidence on corporate cash holdings. *SSRN Electronic Journal*, online: <http://dx.doi.org/10.2139/ssrn.406721>
12. Hausman, J.A. (1978) Specification Tests in Econometrics. *Econometrica*, Vol. 46, No. 6, str. 1251-1271, online: <https://doi.org/10.2307/1913827>
13. Hussain, S., Hassan, A., Bakhsh, A. i Abdullah, M. (2020) The impact of cash holding, and exchange rate volatility on the firm's financial performance of all manufacturing sector in Pakistan. *International Journal of Psychosocial Rehabilitation*, Vol. 24, No. 7, str. 248-261, online: <https://philpapers.org/rec/HUSTIO-16>
14. Hsiao, C. (2014) *Analysis of Panel Data*. 3rd edition, Cambridge University Press, University of Cambridge, Cambridge.
15. Ki, Y. i Adhikari, R. (2022) Corporate Cash Holdings and Exposure to Macroeconomic Conditions. *International Journal of Financial Studies*, Vol. 10, No. 4, str. 1-25, online: <https://doi.org/10.3390/ijfs10040105>
16. Kwan, J-H. i Lau, W-J. (2020) Do Firm Characteristics and Industry Matter in Determining Corporate Cash Holdings? Evidence from Hospitality Firms. *Journal of*

- Asian Finance, Economics and Business*, Vol. 7, No. 2, str. 9-20, online: <https://doi.org/10.13106/jafeb.2020.vol7.no2.9>
17. Martinez-Sola, C., Garcia-Teruel, P. i, Martinez-Solano, P. (2011) Corporate cash holding and firm value. *Applied Economics*, Vol. 45, No. 2, str. 161-170, online: <https://doi.org/10.1080/00036846.2011.595696>
 18. Mesfin, E. (2016) The Factors Affecting Cash Holding Decisions of Manufacturing Share Companies in Ethiopia. *International Journal of Advanced Research in Management and Social Sciences*, Vol. 5, No. 3, str. 48-67, online: <https://ssrn.com/abstract=3386930>
 19. Naumoski, A. (2018) Corporate Cash Holdings: an Empirical Investigation of South-east European Companies. *Economic and Social Development: Book of Proceedings*, str. 339-349.
 20. Opler, T., Pinkowitz, L., Stulz, R. i Williamson, R. (1999) The determinants and implications of corporate cash holdings. *Journal of financial economics*, Vol. 52, No.1, str. 3-46, online: [https://doi.org/10.1016/S0304-405X\(99\)00003-3](https://doi.org/10.1016/S0304-405X(99)00003-3)
 21. Ozkan, A. i Ozkan, N. (2003) Corporate cash holdings: An empirical investigation of UK companies. *Journal of Banking & Finance*, Vol. 28, str. 2103–2134, online: <https://doi.org/10.1016/j.jbankfin.2003.08.003>
 22. Pinkowitz, L., Stulz, R. i Williamson, R. (2015) Do U.S. firms hold more cash?. *The Review of Financial Studies*, Vol. 29, No. 2, str. 309-348, online: <https://doi.org/10.1093/rfs/hhv064>
 23. Sethi, M. i Kumar Swain, R. (2019) Determinants of Cash Holdings: A Study of Manufacturing Firms in India. *International Journal of Management Studies*, Vol. 6, No. 2, str. 11-26, online: [https://doi.org/10.18843/ijms/v6i2\(2\)/02](https://doi.org/10.18843/ijms/v6i2(2)/02)
 24. Tong, Z., (2011) Firm diversification and the value of corporate cash holdings. *Journal of Corporate Finance*, Vol. 17, No. 3, str. 741-758, online: <https://doi.org/10.1016/j.jcorpfin.2009.05.001>

CASH HOLDING DETERMINANTS CONCERNING INDUSTRY AFFILIATION AND FIRM SIZE IN CROATIA

Romina Antić, MEcon

University of Rijeka, Faculty of Economics and Business

e-mail: romina.antic@efri.uniri.hr

Associate Professor Ivana Tomas Žiković, PhD

University of Rijeka, Faculty of Economics and Business

e-mail: ivana.tomas.zikovic@efri.uniri.hr

Associate Professor Kazi Sohag, PhD

Ural Federal University, Graduate School of Economics and Management

University of Rijeka, Faculty of Economics and Business

e-mail: sohagkaziewu@gmail.com

e-mail: kazi.sohag@efri.hr

ABSTRACT

Adequate liquidity, including a sufficient amount of money in a company's transaction accounts, is crucial for successful operations. Therefore, the aim of this study is to analyse the influence of different determinants of cash holdings, such as profitability, debt, growth potential, age of the company, industry, and size of the company, as well as the macroeconomic environment. Furthermore, the study examines whether there are differences in the determinants of cash holdings based on the industry and size of the company. The analysis was conducted on a sample of 19,818 companies in the Republic of Croatia from the trade, construction, and manufacturing industries. The results of the panel analysis indicate that more intensive cash holdings are associated with higher profitability, higher net working capital, better growth prospects, higher debt, elevated financial risk, and longer firm tenure. Conversely, cash holdings tend to decrease when investment activity and GDP growth increase. The results also indicate significant differences in the determinants of cash holdings by firm size, while the analysis at the industry level does not reveal significant differences in the determinants. When companies are grouped by industry and size, the largest differences in the determinants of cash holdings are observed in construction companies.

Key words: cash holding determinants, panel analysis, construction industry, manufacturing industry, trade industry, company size

JEL classification: G30, G32, C23



DIO 5: INVESTICIJE I FINANCIJSKA ODRŽIVOST

ODRŽIVA ULAGANJA: IZAZOVI INTEGRACIJE ESG KRITERIJA U POSLOVNU STRATEGIJU¹

izv. prof. dr. sc. Mihovil Anđelinović

Sveučilište u Zagrebu Ekonomski fakultet

e-mail: mandelinovic@efzg.hr

SAŽETAK

Uspješna primjena održivih praksi omogućuje veće financijske prinose i smanjenje rizika. Održivost postaje ključna tema potaknuta globalnim akcijskim planom UN-a za održivi razvoj do 2030. godine. Istraživanja pokazuju rastući interes ulagača za ESG (okolišni, društveni, upravljački) pristup ulaganjima, dok transparentnost u izvještavanju o održivosti postaje ključna za izgradnju povjerenja i poticanje pozitivnih promjena. No, suočava se s izazovom greenwashinga, gdje se društva predstavljaju s lažnim ili nepotvrđenim tvrdnjama o svojoj održivosti. Svrha ovog rada jest istražiti zastupljenost i interes za održivim ulaganjima te identificirati prepreke kod njihove integracije u poslovne strategije, proučavajući relevantne studije. Prepreke poput nedostatka pouzdanih informacija, nedosljednih rezultata, kao i zabrinutosti oko željenih prinosa i greenwashinga ograničavaju usvajanje održivih praksi. Ulagачi su svjesni rizika, što ističe važnost regulacije, transparentnosti i provjere kvalitete izvještavanja u stvaranju pouzdanog i održivog ulagačkog okruženja. S obzirom na sve navedeno, jasno je da promicanje održivih ulaganja zahtijeva kontinuirane napore za osiguravanje integriteta i autentičnosti praksi ulaganja u skladu s ESG kriterijima.

Ključne riječi: održivost, ESG, održiva ulaganja, financijski rizik, greenwashing

JEL klasifikacija: E44, G11, Q01

1. UVOD

Održiva ulaganja predstavljaju proces identifikacije i ulaganja u poduzeća koja zadovoljavaju određene standarde društveno odgovornog poslovanja (US SIF,

¹ Ovaj rad nastao je u sklopu projekta 2021-1-CZ01-KA220-HED-000031187 ESGs! Sustainable Development Goals in education and in action!

2023a). Radi se o strategiji ulaganja koja teži spojiti okolišne i/ili društvene koristi s financijskim prinosima, na taj način povezujući okolišne, društvene, ekonomske te etičke izazove investitora. Kako Zheng i Jin (2023) pokazuju, zelene investicije imaju stvaran učinak na smanjenje emisija štetnih plinova, a prema Chiju i suradnicima (2023) i na inovativnost poduzeća. Iz tog je razloga korporativna održivost danas postala ključni element poslovne strategije pojedinog društva. Nadalje, održiva ulaganja obuhvaćaju različite kategorije imovine odabrane prema okolišnim, društvenim i upravljačkim faktorima.

Uz brzorastući interes ulagača, postalo je jasno da postoji hitna potreba za boljim definiranjem financijskih karakteristika ove nove paradigme ulaganja, posebno u pogledu izvedbe (GWM Asset Management, 2022). Također, brojna istraživanja (primjerice, Yoon *et al.*, 2018; Muhmad i Muhamad, 2021; Indriastuti *et al.*, 2021; Ray i Goel, 2023) pokazala su da društva koja uključuju ESG kriterije u svoje poslovanje, dugoročno gledano, imaju manju rizičnost i bolji financijski prinos. No, osim regulative, normativni i kognitivni pritisci također su ključni za usmjeravanje poduzeća prema održivim praksama (Khalid *et al.*, 2023).

Plan održivog razvoja do 2030. godine Ujedinjenih naroda (2023) i njihovih sedamnaest ciljeva održivog razvoja predstavljaju globalni akcijski plan za poticanje gospodarskog prosperiteta i društvenog blagostanja uz zaštitu okoliša. U Tablici 1. prikazani su navedeni ciljevi održivog razvoja.

Tablica 1. Ciljevi održivog razvoja Ujedinjenih naroda.

Cilj 1. Svijet bez siromaštva	Cilj 10. Smanjenje nejednakosti
Cilj 2. Svijet bez gladi	Cilj 11. Održivi gradovi i zajednice
Cilj 3. Zdravlje i blagostanje	Cilj 12. Odgovorna potrošnja i proizvodnja
Cilj 4. Kvalitetno obrazovanje	Cilj 13. Zaštita klime
Cilj 5. Rodna ravnopravnost	Cilj 14. Očuvanje vodenog svijeta
Cilj 6. Čista voda i sanitarni uvjeti	Cilj 15. Očuvanje života na zemlji
Cilj 7. Pristupačna energija iz čistih izvora	Cilj 16. Mir, pravda i snažne institucije
Cilj 8. Dostojanstven rad i ekonomski rast	Cilj 17. Partnerstvom do ciljeva
Cilj 9. Industrija, inovacije i infrastruktura	

Izvor: Ujedinjeni narodi (2023)

Na tržištu se pojavljuje nekoliko kategorija održivih ulagača. Održivi ulagači odnose se na pojedince u rasponu od prosječno malih ulagača do onih visoke neto vrijednosti, kao i institucija poput institucionalnih investitora, vjerskih zajednica te različitih neprofitnih institucija i zaklada, a u nastavku su detaljnije definirani:

- pojedinci koji ulažu dio svoje štednje ili mirovinskih planova u uzajamne fondove koji su specijalizirani za ulaganje u društva s dobrom radnom i ekološkom praksom
- kreditne unije i razvojne banke koje imaju posebnu misiju služiti zajednicama s niskim i srednjim prihodima
- bolnice i medicinske škole koje odbijaju ulagati u duhanska poduzeća
- zaklade koje podupiru zajmove za razvoj zajednice i druga ulaganja s visokim društvenim utjecajem
- vjerske institucije koje potiču poduzeća u svojim portfeljima da zadovolje stroge etičke standarde i standarde upravljanja
- investitori rizičnog kapitala koji identificiraju i razvijaju poduzeća koja pružaju okolišne usluge, stvaraju radna mjesta u zajednicama s niskim prihodima ili pružaju druge društvene koristi
- mirovinski fondovi koji potiču poduzeća u koja ulažu da smanje svoje emisije stakleničkih plinova i uključe klimatske promjene u svoje strateško planiranje (US SIF, 2023b).

Osim toga, društva se mijenjaju tijekom vremena, a ulagači utječu pokretanjem ili ubrzavanjem takve promjene. Pojedinačni ulagači pojedinci su koji ulažu vlastiti novac na burzi ili u maloprodajne fondove, dok institucionalni ulagači dio kapitala ili cijeli kapital ulažu na burzi.


Rad se sastoji od četiriju dijelova. Nakon uvodnog dijela, drugi dio istražuje interes i zastupljenost održivosti u kontekstu alokacije resursa zemalja za zelena pitanja te zastupljenosti istih u financijskim izvještajima izdavatelja. Treći dio identificira prepreke i rizike kod integracije ESG pitanja. Četvrti je dio zaključak rada.

2. ZASTUPLJENOST I INTERES ZA TEMOM ODRŽIVOSTI

Kao odgovor na okolišne i društvene izazove globalne industrijalizacije, među ulagačima općenito u zapadnoj Europi i SAD-u postoji sve veći interes za ulaganje imajući na umu okolišna, društvena i upravljačka razmatranja (Kölbel *et al.*, 2020). Naime, Hrvatska gospodarska komora pokrenula je prvu cjelovitu ESG Akademiju u Hrvatskoj, čiji je cilj edukacija, savjetovanje i informiranje poslovnih subjekata i šire javnosti na temu okolišnih, društvenih i upravljačkih kriterija (HGK, 2023).

Prema podacima Eurosifa (2021), gotovo 45 % ukupne raspodjele resursa u nacionalnim planovima oporavka i otpornosti bilo je koncentrirano na zelenu potrošnju, pri čemu Europska unija izdvaja 486,7 milijardi eura, što je vidljivo na Grafikonu 1.

Grafikon 1. Sveukupna raspodjela resursa u nacionalnim planovima oporavka i otpornosti u 2021. godini.




Izvor: Eurosif (2021)

Također, pružanjem transparentnih i točnih informacija o uspješnosti poduzeća u pogledu održivosti, izvještavanje o održivosti pomaže u izgradnji povjerenja i odgovornosti, a istovremeno ubrzava pozitivne promjene i inovacije. S jedne strane, izvještavanje o održivosti pomaže poduzećima pokazati njihovu predanost odgovornim poslovnim praksama, čime mogu poboljšati ugled poduzeća i povećati povjerenje tržišta, a samim time mogu ostvariti i bolji položaj od konkurencije. S druge strane, izvještavanje o održivosti dionicima pomaže u procjeni utjecaja poduzeća i njegova poslovanja na okoliš i društvo, a te su im informacije ključne za ispravno donošenje odluka i mogu im pomoći u razumijevanju potencijalnih rizika i koristi povezanih s ulaganjem u poduzeće ili poslovanje s poduzećem (Brightest, 2023). Prema tome, poduzeća kojima je održivost prioritet mogu stvoriti pozitivan učinak putem inicijative usklađene s ESG kriterijima.

Nadalje, na Grafikonu 2. pokazuje se udio izdavatelja čiji su vrijednosni papiri uvršteni na uređeno tržište Zagrebačke burze, a koji su objavili nefinancijske izvještaje za 2021. i 2022. godinu, podijeljenih po segmentima uređenog tržišta. Pregledom objava svih izdavatelja čiji su vrijednosni papiri uvršteni na

uređeno tržište Zagrebačke burze na dan 31. prosinca 2022. uočeno je da je 49 izdavatelja (52 %) objavilo nefinancijski izvještaj za 2022. ili ga je za njih objavila matica. Uspoređujući to s prethodnom godinom, kada je 42 % izdavatelja objavilo nefinancijski izvještaj, primjetno je povećanje od 10 postotnih bodova. Što se tiče vodećeg tržišta, svi su izdavatelji objavili izvještaj u obje godine, dok je kod službenog i redovitog tržišta vidljiv rast izdavatelja koji ga objavljuju (HANFA, 2022).


Grafikon 2. Udio izdavatelja na uređenom tržištu Zagrebačke burze koji su objavili nefinancijske izvještaje za 2021. i 2022. godinu prema segmentima uređenog tržišta.



Izvor: izrada autora prema HANFA (2022)

Na Grafikonu 3. prikazan je broj nefinancijskih izvještaja istih izdavatelja u kojima su objavljene informacije prema pojedinim područjima, uključujući ekonomsko područje, borbu protiv korupcije, zaštitu okoliša, socijalna pitanja i kadrovska pitanja. U nefinancijskim izvještajima za 2022. svi su izdavatelji objavili informacije o poslovnim rezultatima i financijskom položaju izdavatelja, planiranom razvoju i ulaganjima, kao i o zaštiti okoliša te kadrovskim pitanjima (HANFA, 2022).

Grafikon 3. Broj nefinancijskih izvještaja izdavatelja na uređenom tržištu Zagrebačke burze u kojima su objavljene informacije prema pojedinim područjima.



Izvor: izrada autora prema HANFA (2022)

Uz to, na tržištu održivih ulaganja postoje brojne nove mogućnosti ulaganja koje su privlačne svim ulagačima, djeluju konkurentno i pomažu u rješavanju ozbiljnih društvenih i okolišnih izazova. (HRPSOR, 2023). To uključuje investicije u obnovljive izvore energije poput solarnih i vjetroelektrana, ulaganja u tehnološke inovacije usmjerene na održivost, kao i različite tzv. zelene financijske proizvode poput zelenih obveznica. Međutim, važno je uzeti u obzir rizik održivosti koji može proizaći iznutra ili izvana, što može imati utjecaj na više poslovnih subjekata.

3. RIZIK ODRŽIVOSTI I PREPREKE USVAJANJU ESG PRAKSI

Rizik održivosti definira se kao okolišni, društveni ili upravljački događaj ili uvjet koji, ako se ostvari, može prouzročiti stvarni ili potencijalni materijalni negativni utjecaj na vrijednost ulaganja putem nepovoljnog utjecaja na održivost (Europska unija, 2019). Naime, identifikacija i procjena rizika održivosti sastavni je dio procesa za identifikaciju, kvantificiranje i upravljanje rizikom, stoga je ovu fazu potrebno detaljnije analizirati (Drljača *et al.*, 2015). U nastavku je Tablica 2. koja prikazuje način na koji se mogu identificirati ESG rizici unutar okolišne, društvene i upravljačke kategorije prema specifičnim područjima rizika.

Tablica 2. Načini identifikacije ESG rizika unutar ESG kategorija prema specifičnim područjima rizika.

ESG kategorija	Područje rizika	Rizični događaji
OKOLIŠ	Klimatske promjene	Promjene u politici i regulatornom kontekstu
		Pravovremeni razvoj inovativnih i ekološki odgovornih proizvoda i tehnologije koje podržavaju smanjenje emisija CO ₂ i preferencija potrošača
		Podupiranje smanjenja potrošnje energije u proizvodnim procesima u korist obnovljive energije
		Prekid poslovanja zbog ekstremnih klimatskih događaja (poplave, cikloni) na ključnoj imovini organizacije – tj. fizički rizik
	Odgovorno korištenje prirodnih resursa	Optimiziranje poslovnih procesa u smislu recikliranja, ponovne uporabe dijelova, obnavljanja komponenti i gospodarenja otpadom
		Očuvanje biološke raznolikosti i korištenje zemljišta
		Održivo upravljanje vodama
DRUŠTVO	Upravljanje ljudskim resursima	Zaštita zdravlja i sigurnost na radu
		Privlačenje, zadržavanje i unaprjeđenje ljudskog kapitala profesionalnim razvojem
		Raznolikost, jednake mogućnosti i blagostanje unutar organizacije
	Obveze za proizvode	Pouzdanost proizvoda, jamstvo usklađenosti s propisima o kvaliteti i sigurnosti
	Utjecaj organizacije na zajednice u kojima posluje	Kršenje povjerenja u lokalnim područjima
		Uravnoteženo upravljanje i raspodjela dodane vrijednosti
UPRAVLJANJE	Poslovna etika i integritet (korporativno ponašanje)	Prevenција, otkrivanje i suzbijanje bilo kakvog nezakonitog ponašanja zaposlenika i suradnika (uključujući korupciju, mito i sl.) i usklađenost s povezanim nacionalnim i međunarodnim zakonodavstvom
		Usvajanje odgovornih praksi nabave u cijelom globalnom lancu vrijednosti, sprječavanje kršenja etike

Izvor: izrada autora

Također, izvještaj o riziku opisuje potencijalne rizike s kojima se organizacija može suočiti, kritične rizike koji imaju potencijal za teške posljedice, kao i nove rizike koji bi mogli prouzročiti probleme u budućnosti ako se pažljivo ne prate. Izvještaj također istražuje razne mogućnosti za rješavanje rizika i sprječavanje štetnih ishoda (Indeed, 2022).

Nadalje, manipulativni zeleni marketing (engl. *greenwashing*, u daljnjem tekstu: *greenwashing*) predstavlja novi trend kojem se pojedina društva okreću zbog sve većih zahtjeva tržišta za ekološki prihvatljivim i održivim rješenjima. *Greenwashing* je marketinška taktika koja podrazumijeva da se pojedina društva predstavljaju kao održiva, pružajući lažne, nepotkrijepljene ili izravno obmanjujuće izjave ili tvrdnje o svojim proizvodima ili uslugama (Ires ekologija, 2023). Primjerice, švedski proizvođač odjeće H&M duže vrijeme bio je predmetom općeg interesa i zabrinutosti zbog utjecaja brze mode na okoliš i radnike koji proizvode odjeću. Tijekom proteklog desetljeća, poduzeće je izgubilo značajan udio potrošača zbog tih problema. Proizvodi koji ponekad sadrže i do 100 % poliestera nisu održivi jer se poliester ne razgrađuje s obzirom na to da raspršuje toksična mikrovlakna i ne može se reciklirati. Uz to, H&M tvrdi da su njegovi proizvodi „svjesni“, „svjestan izbor“, „prečac do održivih izbora“, „napravljeni od održivih materijala“ i da će spriječiti da njegov tekstil „ode na odlagalište“ svojim programom recikliranja, a ti se prikazi izrađuju upotrebom zelenih visećih oznaka, natpisa u trgovini i *online* marketinga. Isto tako, H&M je koristio sustav bodovnih kartica za informiranje kupaca o ekološkoj ispravnosti svakog proizvoda, ali izvještaj Quartza (2022) tvrdi da je više od polovice bodovnih kartica prikazivalo proizvode kao bolje za okoliš, nego što zapravo jesu. Izvještaj je, također, ukazao na neke slučajeve u kojima su H&M-ove ekološke tablice rezultata navodno davale informacije o održivosti proizvoda koje su bile potpuno suprotne istini (Green is the New Black, 2023). Bez obzira na to koliko novca H&M ulaže u svoju korporativnu komunikaciju, nepobitna je činjenica da su radnici u tvornicama H&M-a još uvijek daleko od plaća za dostojanstven život. Uz to, preko 540 radnika prijavilo je navodne incidente zlostavljanja između siječnja i svibnja 2021. godine te su okrivili svoje poslodavce za brojne nesavjesnosti na radnom mjestu (ClassAction.org, 2020).

Nadalje, 2022. godine provedena je globalna ESG studija u kojoj je sudjelovalo 565 globalnih institucionalnih ulagača i 565 globalnih stručnjaka, uključujući savjetnike, konzultante i posrednike. Ulagачi su bili smješteni u 19 zemalja i regija iz Europe (50 %), Azije i Pacifika (32 %) te Sjeverne Amerike (18 %). Također, u studiji je sudjelovalo 89 % usvojitelja ESG-a i 11 % korisnika koji nisu usvojili ESG (Capital Group, 2023).

Na temelju podataka u Tablici 3. vidljivo je da se investitore i globalne stručnjake ispitalo koliku važnost pridaju okolišnoj, društvenoj i upravljačkoj komponenti. Također, može se primijetiti da kontinuirana dominacija okolišnog elementa ESG-a pokazuje kako je zabrinutost investitora i globalnih stručnjaka

za klimatske promjene u prvom planu. Investitori i globalni stručnjaci većinu svog fokusa usmjeravaju na E komponentu ESG-a, koja je blago povećala svoj udio u odnosu na prošlu godinu (47 % naspram 44 % u 2021.). Uz to, globalni fokus za društvenu komponentu u 2022. godini ostaje nepromijenjen u odnosu na 2021. godinu, dok se fokus na upravljačku komponentu neznatno smanjio u 2022. godini u odnosu na 2021. Također, investitori i globalni stručnjaci iz Sjeverne Amerike, Azije i Pacifika veću važnost pridaju upravljačkoj komponenti, nego društvenoj, dok investitori i globalni stručnjaci iz Europe veću važnost pridaju društvenoj komponenti, nego upravljačkoj.

Tablica 3. Ispitivanje važnosti ESG komponenti u 2021. i 2022. godini.

	Svijet		Europa		Sjeverna Amerika		Azija-Pacifik	
Godina	2021	2022	2021	2022	2021	2022	2021	2022
Okoliš	44 %	47 %	45 %	48 %	42 %	41 %	44 %	49 %
Društvo	25 %	25 %	25 %	27 %	27 %	25 %	24 %	24 %
Upravljanje	31 %	27 %	30 %	25 %	31 %	34 %	32 %	27 %

Izvor: izrada autora prema Capital Group (2023)

Nadalje, prema podacima u Tablici 4. vidljivo je da se investitore i globalne stručnjake ispitalo koje ih prepreke sprječavaju da usvoje ESG, odnosno da u većoj mjeri usvoje ESG. Kao i prošle godine, nedostatak pouzdanih ESG podataka smatra se najvećom preprekom usvajanja (40 % naspram 49 % u 2021.), dok je zabrinutost oko željenih prinosa druga najveća prepreka. Međutim, daleko manje ulagača ove godine navodi zabrinutost oko željenih prinosa u usporedbi s 2021. (35 % naspram 49 % u 2021.). Treća najveća prepreka usvajanja ESG-a jest zabrinutost oko *greenwashinga* koja je porasla s 22 % u 2021. godini na 30 %. Ove tri najveće prepreke usvajanja ESG-a predstavljaju veći izazov za ulagače u Sjevernoj Americi nego u drugim regijama, pri čemu su nedostatak pouzdanih ESG podataka ocijenili s 46 %, zabrinutost oko željenih prinosa s 49 % i *greenwashing* s 37 %. Iz navedenog može se zaključiti zašto sjevernoamerički investitori imaju najmanje uvjerenja u ESG i zašto ta regija ima najniži postotak korisnika ESG-a. Nadalje, 27 % ispitanika ističe složeno i zbunjujuće regulatorno okruženje kao prepreku usvajanju ESG-a, dok je taj postotak iznosio 24 % u 2021. Navedeno predstavlja veću prepreku usvajanju za europske ulagače i stručnjake (31 %). Također, 26 % ispitanika navodi nedostatak odgovarajućih proizvoda/strategija kao prepreku usvajanju ESG-a, dok 24 % ispitanika smatra fokus industrije na kratkoročne horizonte ulaganja

preprekom usvajanju ESG-a, što prema studiji predstavlja najmanju prepreku usvajanja ESG-a (Capital Group, 2023).

Tablica 4. Stavovi ispitanika o preprekama usvajanju ESG-a.

Prepreke usvajanju ESG-a	2021.	2022.			
	Svijet	Svijet	Europa	Sjeverna Amerika	Azija - Pacifik
Nedostatak pouzdanih ESG podataka	49 %	40 %	41 %	46 %	37 %
Zabrinutost oko željenih prinosa	49 %	35 %	33 %	49 %	31 %
Zabrinutost oko <i>greenwashinga</i>	22 %	30 %	28 %	37 %	28 %
Složeno i zbunjujuće regulatorno okruženje	24 %	27 %	31 %	16 %	26 %
Nedostatak odgovarajućih proizvoda/strategija	27 %	26 %	23 %	21 %	34 %
Fokus industrije na kratkoročne horizonte ulaganja	25 %	24 %	26 %	15 %	25 %

Izvor: izrada autora prema Capital Group (2023)

Nadalje, investitore i globalne stručnjake ispitalo se koji su najbolji načini za suočavanje s izazovima *greenwashinga*, što je vidljivo u Tablici 5. Ispitanici ističu da je povećanje transparentnosti o ulaganjima upravitelja fondova najučinkovitiji način borbe protiv *greenwashinga* (54 % u odnosu na 47 % u 2021.). Nakon toga slijedi povećanje kvalitete i transparentnosti izvještavanja o fondovima u smislu pojedinosti ESG ulaganja i načina na koji će se ona nadzirati (52 % naspram 55 % u 2021.). Također, kako ESG nastavlja dobivati na snazi i postaje sve popularniji oblik ulaganja diljem svijeta, regulacija ima sve veću ulogu u ublažavanju zabrinutosti ulagača oko *greenwashinga*. Naime, 42 % ulagača smatra da je bolja regulatorna provedba jedan od najboljih načina za rješavanje *greenwashinga*. Isti postotak ispitanika, njih 42 %, smatra da bi postavljanje minimalnih regulatornih standarda za održive proizvode i usluge pomoglo u rješavanju *greenwashinga*. No, dok regulatorni okvir pomaže u borbi protiv *greenwashinga*, ulagači ipak smatraju da su upravitelji fondova najbolji za rješavanje tog problema. Također, 38 % ispitanika smatra da je osiguranje kvalitete treće strane i certificiranje jedan od načina borbe protiv *greenwashinga*, pri čemu je taj postotak bio viši 2021. godine (51 %) i predstavljao jedan od najboljih načina za suočavanje s izazovima *greenwashinga*. Uz navedeno, 22 % ispitanika navodi da je pridržavanje ESG oznaka još jedan od načina borbe protiv *greenwashinga* (Capital Group, 2023).

Tablica 5. Ispitivanje najučinkovitijih načina za suočavanje s izazovima greenwashinga u 2021. i 2022. godini.

Najučinkovitiji načini za suočavanje s izazovima greenwashinga	2021.	2022.
Povećanje transparentnosti o ulaganjima upravitelja fondova	47 %	54 %
Povećanje kvalitete i transparentnosti izvještavanja o fondovima	55 %	52 %
Bolja regulatorna provedba	/	42 %
Postavljanje minimalnih regulatornih standarda za održive proizvode i usluge	47 %	42 %
Osiguranje kvalitete treće strane i certificiranje	51 %	38 %
Pridržavanje ESG oznaka	/	22 %

Izvor: izrada autora prema Capital Group (2023)

Dakle, iz svega navedenog može se zaključiti da se nedostatak pouzdanih podataka ponovno smatra najvećom preprekom usvajanja ESG-a. Poteškoće s kvalitetom podataka i nedosljedni rezultati ometaju sposobnost ulagača da usvoje, ugrade i provedu ESG koncept održivog poslovanja.

Iako ispitanici smatraju da je *greenwashing* trenutačno manje raširen, smatraju ga većom preprekom usvajanju nego prošle godine. Prema Tablici 6. može se zamijetiti da su ispitanici zabrinutiji zbog potencijalnog skandala s lažnom prodajom, što podrazumijeva situaciju u kojoj se proizvod ili usluga namjerno lažno predstavlja ili je kupac doveden u zabludu o njihovoj održivosti (52 % naspram 48 % u 2021. godini). Uz to, zabrinutost zbog potencijalnog skandala s lažnom prodajom najviše je porasla među ispitanicima u Sjevernoj Americi (49 % naspram 36 % u 2021. godini), iz čega se također može vidjeti zašto su sjevernoamerički investitori skeptični u vezi usvajanja ESG-a.

Tablica 6. Ispitivanje zabrinutosti ispitanika vezano uz potencijalni skandal s lažnom prodajom u 2021. i 2022. godini.

	2021.			2022.		
Svijet	48 %	42 %	10 %	52 %	34 %	14 %
Europa	54 %	38 %	9 %	56 %	29 %	15 %
Sjeverna Amerika	36 %	56 %	9 %	49 %	40 %	12 %
Azija-Pacifik	44 %	41 %	15 %	47 %	39 %	13 %

Izvor: izrada autora prema Capital Group (2023). *Napomena: U tablicama za 2021. i 2022. godinu lijevi stupac označava ispitanike koji su odabrali odgovor „Slažem se”, srednji stupac „Niti se slažem niti se ne slažem”, a desni stupac „Ne slažem se”.*

Međutim, europski ispitanici i globalni stručnjaci najviše su zabrinuti zbog potencijalnog skandala s lažnom prodajom (56 % naspram 54 % u 2021. godini), dok 14 % ispitanika tvrdi da nisu zabrinuti oko skandala s lažnom prodajom

(Capital Group, 2023). Daljnja istraživanja i naponi za poboljšanje pouzdanosti podataka te regulacija u području ESG-a ključni su u prevladavanju prepreka koje sputavaju širenje održivih ulaganja. Uz to, transparentnost, kvalitetno izvještavanje i bolji nadzor pomoći će u suočavanju s izazovima poput *greenwashinga* te omogućiti održivim ulaganjima da ostvare svoj puni potencijal u stvaranju pozitivnog društvenog i okolišnog utjecaja.

4. ZAKLJUČAK

Održiva ulaganja postaju ključna strategija ulaganja, koja spaja socijalne, okolišne i ekonomske aspekte, a cilj joj je postizanje financijskih prinosa uz istovremeno promicanje društveno odgovornih poslovnih praksi. Održiva ulaganja imaju sve veći interes ulagača zbog dokazane veze između integracije ESG (okolišnih, društvenih i upravljačkih) kriterija i dugoročne financijske uspješnosti. Različite skupine ulagača sudjeluju na tržištu održivih ulaganja, uključujući pojedince, institucije, zaklade, vjerske organizacije i druge. Postoje različite strategije koje održivi ulagači primjenjuju, uključujući ulaganje u poduzeća koja promiču društvenu odgovornost, smanjenje emisija stakleničkih plinova ili podršku razvoju zajednica.

Istraživanja su pokazala da transparentno izvještavanje o korporativnoj održivosti pomaže izgradnji povjerenja i podržava pozitivne promjene i inovacije. Međutim, manipulativni zeleni marketing (*greenwashing*) predstavlja ozbiljan problem jer neka poduzeća prikazuju lažne ili neodržive tvrdnje o svojim proizvodima ili uslugama, što dovodi do nedostatka povjerenja potrošača. Nedostatak pouzdanih ESG podataka, zabrinutost oko željenih prinosa i *greenwashing* glavne su prepreke za veće usvajanje ESG-a. Povećanje transparentnosti, bolje izvještavanje, regulacija i uspostavljanje minimalnih standarda za održive proizvode identificirani su kao ključni mehanizmi borbe protiv *greenwashinga*.

U budućim istraživanjima nužno je detaljnije istražiti najbolje prakse integracije ESG-a u poslovnu strategiju, analizirati utjecaj različitih ESG faktora na uspjeh poduzeća i procijeniti efikasnost regulatornih mjera u suzbijanju *greenwashinga*. Iako ovaj rad pruža osnovno razumijevanje trenutnog stanja i ključnih izazova u području održivih ulaganja, ističe se potreba za dubljom analizom i istraživanjem u područjima koja su identificirana kao ključna.

S obzirom na sve veću važnost održivih ulaganja za globalne financije, kontinuirano istraživanje i analiza ovog područja postaju imperativ za razvoj efikasnih

strategija ulaganja koje istovremeno promiču održivost i ostvaruju financijske rezultate. Ključno je rješavanje prepreka poput nedostatka pouzdanih podataka i suzbijanja *greenwashinga* kako bi se ostvario daljnji napredak i povećala svijest o važnosti društveno odgovornog ulaganja.

REFERENCE

1. Brightest (2023) The Top 7 Sustainability Reporting Standards in 2023. Dostupno na: <https://www.brightest.io/sustainability-reporting-standards> [2. listopada 2023.]
2. Capital Group (2023) ESG Global Study 2022. Dostupno na: <https://www.capital-group.com/advisor/pdf/shareholder/ITGEOT-028-658081.pdf> [4. listopada 2023.]
3. Chi, Y., Hu, N., Lu, D., i Yang, Y. (2023) Green investment funds and corporate green innovation: From the logic of social value, *Energy Economics*, Vol. 119, 106532. Dostupno na: <https://doi.org/10.1016/j.eneco.2023.106532> [4. listopada 2023.]
4. ClassAction.org (2020) Commodore v. H&M Hennes & Mauritz LP. Dostupno na: <https://www.classaction.org/media/commodore-v-h-and-m-hennes-and-mauritz-lp.pdf> [3. listopada 2023.]
5. Drljača, M., Bešker, M. i Čiček, J. (2015) Unutarnji i vanjski kontekst organizacije, *Zbornik radova 16. međunarodnog simpozija o kvaliteti Kvaliteta i konkurentnost*, Hrvatsko društvo menadžera kvalitete, Opatija, 2015, str. 455-472.
6. Europska unija (2019), Uredba (EU) 2019/2088 Europskog parlamenta i vijeća od 27. studenoga 2019. o objavama povezanim s održivosti u sektoru financijskih usluga. Dostupno na: <https://eur-lex.europa.eu/legal-content/HR/TXT/HTML/?uri=CELEX:32019R2088> [5. listopada 2023.]
7. Eurosif (2021) Eurosif report 2021: Fostering Investor Impact – Placing it at the heart of sustainable finance. Dostupno na: <https://www.eurosif.org/news/eurosif-report-2021/> [2. listopada 2023.]
8. Green is the New Black (2022) H&M Has Been Caught Greenwashing, Again. Now What?. Dostupno na: <https://www.greenisthenewblack.com/hm-has-been-caught-greenwashing-again-now-what/> [30. svibnja 2023.]
9. GWM Asset Management (2022) Why is sustainable investment important?. Dostupno na: <https://gwmam.co.uk/why-is-sustainable-investing-important/> [3. listopada 2023.]
10. Hrvatska agencija za nadzor financijskih usluga (HANFA) (2022) Godišnji izvještaj o korporativnom upravljanju 2022. Dostupno na: <https://www.hanfa.hr/media/3hse-va3/giku-2022.pdf> [17. studenoga 2023.]
11. Hrvatska Gospodarska Komora (HGK) (2023) ESG Akademija HGK. Dostupno na: <https://www.hgk.hr/esg-akademija-hrvatske-gospodarske-komore-najava-1> [3. listopada 2023.]
12. Hrvatski poslovni savjet za održivi razvoj (HRPSOR) (2023) ESG kriteriji su izazov, ali i prilika. Dostupno na: <https://www.hrpsor.hr/esg-kriteriji-su-izazov-ali-i-prilika/> [4. listopada 2023.]

13. Indeed (2022) What Is a Risk Report? (With Types and Steps To Write One). Dostupno na: <https://www.indeed.com/career-advice/career-development/risk-report> [2. listopada 2023.]
14. Indriastuti, M. i Chariri, A. (2021) The role of green investment and corporate social responsibility investment on sustainable performance, *Cogent Business & Management*, Vol. 8, No. 1, 1960120. Dostupno na: <https://doi.org/10.1080/23311975.2021.1960120> [4. listopada 2023.]
15. Ires ekologija (2023) Greenwashing: Kako znati koji su proizvođači zaista zeleni?. Dostupno na: <https://ires-ekologija.hr/zeleni-proizvodci-i-usluge-kako-razlikovati-one-koji-to-zaista-jesu/> [4. listopada 2023.]
16. Khalid, F., Naveed, K., Nawaz, R., Sun, X., Wu, Y. i Ye, C. (2023) Does corporate green investment enhance profitability? An institutional perspective, *Economic research-Ekonomska istraživanja*, Vol. 36, No. 1, str. 1-24. Dostupno na: <https://doi.org/10.1080/1331677X.2022.2063919> [1. listopada 2023.]
17. Kölbel, J. F., Heeb, F. i Busch, T. (2020) Can Sustainable Investing Save the World? Reviewing the Mechanisms of Investor Impact, *Organization & Environment*, Vol. 33, No. 4, str. 3-17. Dostupno na: <https://doi.org/10.1177/1086026620919202> [1. listopada 2023.]
18. Muhmad, S. N. i Muhamad, R. (2021) Sustainable business practices and financial performance during pre- and post-SDG adoption periods: a systematic review, *Journal of Sustainable Finance & Investment*, Vol. 11, No. 4, str. 291-309. Dostupno na: <https://doi.org/10.1080/20430795.2020.1727724> [7. listopada 2023.]
19. Quartz (2022) Quartz investigation: H&M showed bogus environmental scores for its clothing. Dostupno na: <https://qz.com/2180075/hm-showed-bogus-environmental-higg-index-scores-for-its-clothing/> [3. listopada 2023.]
20. Ray, R. S. i Goel, S. (2023) Impact of ESG score on financial performance of Indian firms: static and dynamic panel regression analyses, *Applied Economics*, Vol. 55 No. 15, str. 1742-1755. Dostupno na: <https://doi.org/10.1080/00036846.2022.2101611> [7. listopada 2023.]
21. Ujedinjeni Narodi (UN) (2023) Sustainable Development Goals. Dostupno na: <https://sdgs.un.org/goals> [1. listopada 2023.]
22. US SIF: Sustainable Investment Forum (2023a) Blog. Dostupno na: https://www.ussif.org/blog_home.asp?Display=194 [3. listopada 2023.]
23. US SIF: Sustainable Investment Forum (2023b) Sustainable Investing Basics. Dostupno na: <https://www.ussif.org/sribasics> [1. listopada 2023.]
24. Yoon, B., Lee, J. H. i Byun, R. (2018) Does ESG Performance Enhance Firm Value? Evidence from Korea, *Sustainability*, Vol. 10, No. 10, str. 1-18. Dostupno na: <https://doi.org/10.3390/su10103635> [7. listopada 2023.]
25. Zheng, S. i Jin, S. (2023) Is corporate green investment a determinant of corporate carbon emission intensity? A managerial perspective, *Heliyon*, Vol. 9, No. 12, e22401. Dostupno na: <https://doi.org/10.1016/j.heliyon.2023.e22401> [7. listopada 2023.]

SUSTAINABLE INVESTMENTS: CHALLENGES OF INCORPORATING ESG CRITERIA INTO CORPORATE STRATEGY²

Associate Professor Mihovil Anđelinović, PhD

University of Zagreb Faculty of Economics and Business

e-mail: mandelinovic@efzg.hr

ABSTRACT

The successful implementation of sustainable practices allows for higher financial returns and risk mitigation. The focus on sustainability has gained prominence due to the UN's global strategy aiming for sustainable development by 2030. Research indicates a growing interest among investors in the ESG (Environmental, Social, Governance) investment approach, while transparency in sustainability reporting is becoming key to building trust and driving positive change. Nonetheless, this approach encounters the obstacle of greenwashing, wherein companies make false or unverified claims about their sustainability. This paper aims to investigate the prevalence and interest in sustainable investments and to identify barriers to their integration into business strategies by examining relevant studies. Barriers such as a lack of reliable information, inconsistent results, and concerns about desired returns and greenwashing limit the adoption of sustainable practices. Investors are aware of these risks, highlighting the importance of regulation, transparency, and verification of reporting quality in creating a reliable and sustainable investment environment. Considering all the above, it is evident that promoting sustainable investments requires continuous efforts to ensure the integrity and authenticity of investment practices in line with ESG criteria.

Keywords: sustainability, ESG, sustainable investments, financial risk, greenwashing

JEL classification: E44, G11, Q01

² This paper was created as part of the project 2021-1-CZ01-KA220-HED-000031187 ESDGs! Sustainable Development Goals in education and in action!

FINANCIJSKI ASPEKTI PLAVE EKONOMIJE UNUTAR PERSPEKTIVE EU-A

izv. prof. dr. sc. Sonja Brlečić Valčić

Sveučilište u Zadru, Odjel za ekonomiju
e-mail: sbrlecicv@unizd.hr

Marijana Jerić, mag. oec.

Sveučilište u Zadru, Odjel za ekonomiju
e-mail: mjeric@unizd.hr

doc. dr. sc. Jurica Bosna

Sveučilište u Zadru, Odjel za ekonomiju,
e-mail: jbosna@unizd.hr

SAŽETAK

U ovom radu autori istražuju zamršene financijske aspekte plave ekonomije unutar Europske unije (EU). Analizirajući ulaganja, ekonomske učinke, izazove i političke implikacije, rad donosi spoznaju o financijskoj održivosti plavog gospodarstva EU-a. Analiza provedena putem hijerarhijskog klasteriziranja podataka odabranih članica EU-a naglašava odnose između osoba zaposlenih u sektoru plave ekonomije, dodane vrijednosti po faktorskim troškovima, neto ulaganja i bruto dodane vrijednosti. Promatrani podsektori su primarna proizvodnja, neproizvodne djelatnosti, luke, brodogradnja, pomorski transport i obalni turizam. Rezultati analize naglašavaju da su strateško planiranje i koordinirani naponi u ovim međusobno povezanim sektorima ključni za poticanje održivog i ekonomski održivog rasta u plavoj ekonomiji, a razumijevanje međuodnosa promatranih sektora i kategorija ključno za poticanje održivog rasta, maksimiziranje mogućnosti zapošljavanja i promicanje inovacija.

Ključne riječi: *plava ekonomija, dodana vrijednost, neto ulaganja, strateško planiranje, financijska održivost*

JEL klasifikacija: E02, E23, E23, Q56

1. UVOD

Plava ekonomija, koja uz pomorsku industriju i s njom povezane obalne aktivnosti obuhvaća održivo gospodarenje ribarskim aktivnostima, turizam i obalni razvoj, održive energetske sustave iz mora, pomorsku robnu razmjenu i s njom u vezi ekonomsko povezivanje, biotehnologiju i morsku farmaceutiku, ekonomsko vrednovanje mora i priobalja, klimatske implikacije te inovacije i tehnološke transfere, igra ključnu ulogu u gospodarskom krajoliku EU-a. Koncept plavog gospodarstva, kako ga definiraju ključne institucije kao što su Svjetska banka, Europska komisija, Ujedinjeni narodi i *The Economist*, konvergira na održivom korištenju morskih resursa za postizanje gospodarskog rasta, dok je prioritet dobrobit stanovništva i očuvanje okoliša. Ove definicije zajedno naglašavaju međusobno povezanu prirodu gospodarskih aktivnosti povezanih s oceanima, morima i obalama, potičući ravnotežu između gospodarskog prosperiteta i dugoročnog zdravlja morskih ekosustava. Prema podacima Svjetske banke u Europi, plavo gospodarstvo predstavlja gotovo 5,4 milijuna radnih mjesta i stvara bruto dodanu vrijednost od približno 500 milijardi eura godišnje (Stanca *et al.*, 2018).

Primarni cilj ovog rada jest pružiti sveobuhvatnu analizu financijskih aspekata svojstvenih plavom gospodarstvu EU-a. Preciznim istraživanjem ulaganja, ekonomskih učinaka, izazova i političkih implikacija, autori nastoje rasvijetliti financijsku održivost različitih sektora koji čine okvir plave ekonomije. Opseg rada nadilazi puko ispitivanje financijskih metrika te se u radu nastoje razotkriti inherentni odnosi koji povezuju promatrane podsektore. Značaj leži u dešifriranju zamršenih veza između obrazaca zapošljavanja, dodane ekonomske vrijednosti, ulaganja i ukupne ekonomske proizvodnje unutar plave ekonomije.

Preliminarni rezultati ovog istraživanja naglašavaju potrebu za strateškim planiranjem i koordiniranim naporima u međusobno povezanim sektorima za poticanje održivog i ekonomski održivog rasta. Analiza hijerarhijskog klasteriranja otkriva nijanse u odnosima između zaposlenih osoba, dodane vrijednosti, neto ulaganja i bruto dodane vrijednosti u promatranim podsektorima. Strateški uvidi izvedeni iz ovih rezultata ključni su za kreatore politike, dionike u industriji i istraživače. Razumijevanje financijske dinamike plavog gospodarstva EU-a najvažnije je za njegovo usmjeravanje prema održivoj i prosperitetnoj budućnosti. Potreba za informiranim odlučivanjem na temelju provedenih analiza postaje očita. Stoga, ovaj rad značajno doprinosi razotkrivanju složenosti i oslobađanju potencijala plavog gospodarstva EU-a, potičući rast koji nije samo ekonomski snažan nego je i ekološki i društveno odgovoran. Rad se sastoji od ukupno pet poglavlja. Prvo poglavlje je uvod u kojem se navodi

problem, cilj i svrha istraživanja. Drugo poglavlje bavi se potencijalom i transformacijskim aspektima plavog gospodarstva EU-a. Treće poglavlje je metodologija u kojoj su navedeni postupci provedenog istraživanja, odabir podataka i metodologija korištena za njihovu analizu. Rezultate istraživanja i njihovu diskusiju iznosi četvrto poglavlje, dok je peto poglavlje zaključak u kojem se navode najvažniji zaključci provedenog istraživanja.

2. POTENCIJAL I TRANSFORMACIJSKI ASPEKTI PLAVOG GOSPODARSTVA EU-A

U kontekstu istraživanja održivog razvoja, diskurs o plavoj ekonomiji prvenstveno se fokusira na četiri teme: temeljnu teoriju, ekološku održivost, metode razvoja mora i sveobuhvatne koristi i funkcije (Lee *et al.*, 2021). Unatoč svom potencijalu, kružna ekonomija selektivno se razvijala, često zanemarujući pomalo radikalne transformacijske aspekte usmjerene na čovjeka u korist gospodarskog rasta vođenog poslovanjem (Voyer *et al.*, 2022). Premošćivanje ovih izazova zahtijeva holistički pristup koji se bavi ekonomskim, društvenim i ekološkim dimenzijama, potičući istinski održivo i pravedno plavo gospodarstvo.

2.1. EKONOMSKA DIMENZIJA PODRUČJA PLAVE EKONOMIJE

Složen odnos između plave ekonomije i cjelokupnog okoliša isprepliće specifične aspekte, kao što su rast, prostorno planiranje, upravljanje okolišem i održivost (Lee *et al.*, 2021). Dok plava ekonomija daje prioritet ekonomskim i ekološkim ciljevima, često zanemaruje uključenost u ciljeve pravednosti, posebno u područjima kao što su sigurnost hrane i rodna ravnopravnost (Voyer *et al.*, 2022). Prepoznajući ovaj jaz, zamišljena je transformacijska plava ekonomija, ona koja društvene koristi i jednakost stavlja u isti rang s ekološkim i ekonomskim brigama. Ovaj je pomak ključan za postizanje ciljeva održivog razvoja, primjerice, u pomorskim sektorima (Cisneros-Montemayor, 2021). Španjolske luke svjedoče nastanku ključnih sektora unutar plavog gospodarstva, uključujući biotehnologiju, istraživanje i obrazovanje, održivu infrastrukturu te gastronomiju i tradiciju (Camarero Orive *et al.*, 2022). Ovi sektori imaju potencijal za poboljšanje održivog razvoja, gospodarskog rasta i sigurnosti u regiji.

Dok plava ekonomija može imati kapacitet nadmašiti svjetsku ekonomiju u dodanoj vrijednosti i zapošljavanju, rješavanje izazova ekonomske ekspanzije i balansiranje ekološke odgovornosti postaje imperativ. Ovaj gospodarski i ekološki po-

tencijal predstavlja priliku za modernizaciju iz ekonomske, geopolitičke i ekološke perspektive. Međutim, to također predstavlja izazove za globalno upravljanje morima i oceanima (Doyle, 2018). Plavo gospodarstvo, ako se strateški iskoristi, može olakšati održivi gospodarski razvoj, doprinijeti očuvanju okoliša i klime te potaknuti inovacije i rast. Identifikacija 100 tehnologija nadahnutih prirodom dodatno naglašava njihov potencijal da pozitivno utječu na gospodarstva i zadovolje osnovne ljudske potrebe uz promicanje održivih ekosustava (Pauli, 2021).

Inovacija poslovnog modela plave ekonomije, prikazana modeliranjem, nudi dokaz koncepta za premošćivanje stvaranja vrijednosti i pozitivnog utjecaja na društvo i okoliš (Zsifkovits *et al.*, 2016). To ne samo da doprinosi boljoj otpornosti u društvu nego i jača demokraciju. Društveni i gospodarski potencijal plavog gospodarstva može se dodatno otključati javno-privatnim partnerstvi i konvencionalnim financijskim instrumentima koji potiču rast i održivost (Cisneros-Montemayor *et al.*, 2019). Sigurnost igra ključnu ulogu u plavoj ekonomiji, utječući na ekonomsku, ekološku i političku sigurnost resursa (Jacob i Umoh, 2022). Ukorijenjene u povijesnim naporima da se osigura oceanski prostor, sadašnje tehnologije pokreću ovaj pristup. Kako bi se osigurao uspjeh plavog gospodarstva, ono bi trebalo biti povezano s uslugama ekosustava i održivošću, uključujući održivi okvir koji uzima u obzir iscrpljivanje ekosustava i netržišne koristi.

Isticanje potrebe za savezima između sektora ključno je za postizanje održivog rasta kako u razvijenim zemljama tako i u zemljama u razvoju. Plava ekonomija, stoga, mora biti promatrana kao složen vladin projekt pojedine države jer stvara nove prostore upravljanja i racionalizira ga, preobličujući ljude i resurse u različitim geografskim kontekstima. Humani geografi mogu, u tom kontekstu, doprinijeti kombiniranjem biološkog i ekonomskog znanja, promicanjem informiranog i kritičkog angažmana.

2.2. DRUŠTVENI ASPEKTI PLAVE EKONOMIJE

Društveni aspekti plave ekonomije zahtijevaju sveobuhvatan pristup koji daje prioritet pravednosti, uključenosti i angažmanu zajednice. Usklađujući ekonomska, ekološka i društvena pitanja, plava ekonomija postaje snažna sila za pozitivnu društvenu transformaciju i održivi razvoj. Davanje prioriteta društvenim koristima i pravednosti, uz ekološka i ekonomska razmatranja, imperativ je u kontekstu društvenih aspekata plave ekonomije (Cisneros-Montemayor *et al.*, 2019). Ovaj pristup osigurava da ciljevi održivog razvoja ne budu samo

ekološki i ekonomski održivi nego i socijalno inkluzivni i pravedni. Utjecaj plave ekonomije proteže se izvan područja gospodarstva i okoliša, a također djeluje putem uvjeravanja, konstrukcije „zdravorazumske“ putanje i odnosa društvene moći (Schutter *et al.*, 2021). Taj utjecaj pridonosi depolitizaciji u raspravama o zajedničkoj viziji plave ekonomije, oblikovanju perspektiva i poticanju pristupa koji se temelji na konsenzusu.

Plava ekonomija, kada se učinkovito provodi, služi kao katalizator socijalne uključenosti, gospodarskog rasta i očuvanja ili povećanja sredstava za život. Taj se učinak očituje u stvaranju gotovo 5,4 milijuna radnih mjesta i približno 500 milijardi eura dodane vrijednosti godišnje (Stanca *et al.*, 2018). Dajući prioritet socijalnoj jednakosti, plava ekonomija postaje snaga za pozitivne promjene, od koje koristi imaju pojedinci i zajednice. Međutim, ključno je riješiti tendenciju zanemarivanja socijalne jednakosti u inicijativama plavog gospodarstva i plavog rasta na nacionalnoj razini. Posljedice ovog nadzora očituju se u procesima kao što su otimanje obale i oceana, raseljavanje i isključivanje, nerazmjerno utječući na marginalizirane obalne zajednice i male ribare. Ispravljanje ove neravnoteže ključno je za osiguravanje pravedne podjele koristi od plavog gospodarstva (Das, 2023).

Ispitujući praktičnu primjenu koncepta plave ekonomije, njegova implementacija na turističkim odredištima može povećati prihode od turizma uz pozitivan utjecaj na društveni sektor i poticanje tehnološkog razvoja (Das, 2023). Ovo pokazuje kako plavo gospodarstvo može biti katalizator holističkog društvenog napretka na lokalnoj razini. S ciljem premošćivanja jaza između stvaranja vrijednosti i pozitivnog sociookolišnog utjecaja, plava ekonomija postaje snažan instrument za jačanje otpornosti društva i jačanje demokratskih načela (Zsifkovits *et al.*, 2016). Ovaj koncept osigurava ekološku i društvenu održivost u pomorskom i obalnom turizmu, čime se potiče gospodarski rast na društveno odgovoran način (Tegar i Gurning, 2018). U uspješnim inicijativama plavog gospodarstva ključan je naglasak na uključenosti lokalne zajednice, odnosno ove inicijative daju prioritet održivosti ekosustava, težeći ravnoteži između ekonomske, društvene i ekološke dimenzije. Na taj način ovaj pristup naglašava važnost angažmana zajednice u osiguravanju cjelokupnog uspjeha i održivosti projekata plave ekonomije (Okafor-Yarwood *et al.*, 2020). Postizanje te ravnoteže zahtijeva ne samo ekonomske doprinose BDP-u nego i snažnu političku volju, obveze i povećanu društvenu svijest. Ovaj integrirani pristup neophodan je za iskorištavanje svih prednosti povezanih s plavom ekonomijom (Bari, 2017).

2.3. EKOLOŠKA DIMENZIJA PODRUČJA PLAVE EKONOMIJE

Ekološki aspekti plavog gospodarstva naglašavaju transformacijski cilj: pomaćniti društvo s paradigme oskudice na paradigmu obilja (Kathijotes, 2013). Ova transformacija uključuje sveobuhvatan pristup rješavanju gorućih ekoloških problema, uključujući unos tvari iz gradskih otpadnih voda, ispusta oborinskih voda i akvakulture (Kathijotes, 2013). Rješavanjem ovih izazova, plava ekonomija ima za cilj uvesti eru u kojoj se ekološka pitanja rješavaju zajedno s ekonomskim razmatranjima (Okafor-Yarwood *et al.*, 2020).

Središnje mjesto u ovom ekološkom pristupu jest naglasak na uključivanju lokalne zajednice i promicanju održavanja prirodnih ekosustava (Tegar i Gurning, 2018). Cilj je postići delikatnu ravnotežu održivosti. Dajući prioritet zdravlju prirodnih ekosustava, plava ekonomija usklađuje se s načelima ukorijenjenima u ekološkim sustavima (Biukšane, 2022). Utemeljeno na načelima ekosustava, plavo gospodarstvo osigurava ekološku održivost u morskom i obalnom turizmu. Ovaj je pristup ključan za održavanje osjetljive ravnoteže ovih okoliša i poticanje turizma koji je i ekonomski održiv i ekološki odgovoran. Prepoznajući središnju ulogu plavog gospodarstva u održivom razvoju, njegov okvir uključuje, uz socioekonomske koristi, i očuvanje okoliša (Biukšane, 2022). Ovaj fokus proteže se na oceane i morski okoliš te njegovu bogatu biološku raznolikost, naglašavajući važnost očuvanja ovih ekosustava za sadašnje i buduće generacije. Potencijal plavog gospodarstva da omogući održivi gospodarski razvoj i pridonese očuvanju okoliša i ublažavanju klimatskih promjena kamen je temeljac njegove priče o okolišu. Ovaj višestruki utjecaj naglašava međusobnu povezanost gospodarskog rasta, zdravlja okoliša i otpornosti na klimatske promjene. Prihvaćajući suvremeni koncept interakcije društva i prirode putem gospodarstva, plava ekonomija nastoji očuvati prirodu i osigurati prirodne uvjete za život ljudi. Ovaj pristup označava promjenu paradigme, priznajući neraskidivu vezu između uspješnog gospodarstva i zdravog okoliša (Sverdan, 2021).

Stoga, plava ekonomija aktivno teži razvoju tehnologije inspirirane prirodom koje su sposobne održivo osigurati osnovne ljudske potrebe, uključujući pitku vodu, hranu, radna mjesta i zdravo sklonište (Pauli, 2021). Ova predanost naglašava važnost iskorištavanja inovacija koje su u skladu s prirodnim okolišem i čuvaju ga. Ključni ekološki imperativ unutar plavog gospodarstva je izgradnja otpornosti morskog ekosustava na klimatske promjene. Ovo naglašava potrebu za proaktivnim mjerama za zaštitu i poboljšanje sposobnosti prilagodbe morskih ekosustava koji se suočavaju s izazovima koje donosi promjena klime

(Sarker *et al.*, 2019). Prepoznajući holističku prirodu ekosustava, uključivanje ljudskih dimenzija u integrirane procjene ekosustava smatra se temeljnim za postizanje svih prednosti plavog gospodarstva (Link *et al.*, 2017).

Ovaj holistički pristup osigurava neprimjetno integriranje socioekonomskih i okolišnih pitanja u procese donošenja odluka. Inovativni pristup unutar plavog gospodarstva uključuje, između ostalog, i povećanje potopljenog morskog ugljika (plavi ugljik) putem aktivnosti marikulture. Ovaj obećavajući pristup ne samo da ublažava klimatske promjene nego je i usklađen s ciljem promicanja gospodarstva s niskom razinom ugljika (Zhang *et al.*, 2017). U tom se kontekstu, primjerice, i bio rafinerije mikro algi ističu kao obećavajuća tehnologija unutar plavog gospodarstva, s potencijalom smanjenja emisija CO₂ iz termoelektrana (Costa *et al.*, 2019). Osim toga, ove bio rafinerije mogu proizvoditi biogoriva i visokovrijedne proizvode, značajno pridonoseći ekološkim ciljevima plavog gospodarstva. Sumarno, ekološki aspekti plavog gospodarstva zalažu se za skladan odnos između gospodarskih aktivnosti i ekološkog blagostanja. Rješavanjem ekoloških izazova, poticanjem održivosti i prihvatanjem tehnologija nadahnutih prirodom, plava ekonomija pojavljuje se kao transformacijska snaga za pozitivan utjecaj na okoliš unutar globalnog ekonomskog okvira.

3. ODABIR PODATAKA I METODOLOGIJA KORIŠTENIH U ANALIZI

3.1. OPIS ANALIZIRANIH PODATAKA U OKVIRU PLAVE EKONOMIJE

Sukladno istaknutim ciljevima istraživanja u analizama korišteni su javno dostupni podaci iz baze podataka Europske komisije koje prati izvješće *EU Blue Economy Report 2023* te su prikazani u Tablici 1.

Tablica 1. Podaci korišteni u analizi

Osobe zaposlene u sektoru plave ekonomije	
1	Živi resursi
2	Neživi resursi
3	Aktivnosti luka
4	Brodogradnja i remont
5	Pomorski transport
6	Obalni turizam
7	Bruto dodana vrijednost (BVP) po zaposlenom

Dodana vrijednost po faktorskim troškovima (milijuni eura)	
8	Živi resursi
9	Neživi resursi
10	Aktivnosti luka
11	Brodogradnja i remont
12	Pomorski transport
13	Obalni turizam
Neto ulaganje: podsektori (milijuni eura)	
14	Primarna proizvodnja
15	Prerada ribljih proizvoda
16	Distribucija ribljih proizvoda
17	Nafta i plin
18	Ostali minerali
19	Projekti luka i voda
20	Brodogradnja
21	Oprema i strojevi

Izvor: izradili autori prema *EU Blue Economy Report 2023*

Vremenska domena podataka obuhvaća razdoblje od 2016. do 2019. godine. U analizi nije korištena analiza vremenskih nizova, već je svaka godina promatrana kao jedno mjerenje u skupu podataka. Promatrane države su Španjolska, Francuska, Italija, Malta, Slovenija, Hrvatska i Grčka. Sektor živih resursa obuhvaća izlov obnovljivih bioloških resursa (primarna proizvodnja), njihovu pretvorbu u hranu, stočnu hranu, bio proizvode i bioenergiju (prerada) te njihovu distribuciju duž opskrbnog lanca. EU je šesti najveći proizvođač ribarskih proizvoda i proizvoda akvakulture (iza Kine, Indonezije, Indije, Vijetnama i Perua), pokrivajući oko 2 % globalne proizvodnje. EU ima oko 56 100 aktivnih plovila koja iskrcavaju oko 3,9 milijuna tona plodova mora u vrijednosti od 5,8 milijarde eura, dok je sektor akvakulture dosegao proizvodnju od oko 1,2 milijuna tona u vrijednosti od 3,9 milijarde eura u 2020. godini.

Prerada i distribucija morskih proizvoda uvelike ovise o nabavi sirovina iz primarne proizvodnje. Visoka potrošnja i povećana potražnja za morskim proizvodima te stagnacija u primarnoj proizvodnji čine ove djelatnosti sve ovisnijima o uvozu iz trećih zemalja. Zapravo, EU je najveći uvoznik plodova mora na svijetu. Njegova samodostatnost u zadovoljavanju rastuće potražnje za plodovima mora iz vlastitih voda jest oko 30 %, tj. građani EU-a trošili su više od tripud više nego što su proizvodili. Prema statističkim podacima o ribarstvu i akvakulturi za 2020. godinu Organizacije Ujedinjenih naroda za hranu i poljoprivredu, građani EU-a u prosjeku konzumiraju oko 24 kg plodova mora i potroše oko 100,00 € na plo-

dove mora godišnje. Glavni proizvodi koji se konzumiraju su tuna (uglavnom konzervirana), bakalar, losos, aljaška kolja, škampi, dagnje i haringe.

Sektor živih resursa sastoji se od triju podsektora koji su dalje raščlanjeni na sljedeće aktivnosti:

1. primarna proizvodnja: lovno ribarstvo (male obalne, velike i industrijske flote) i akvakultura (morska, slatkovodna i školjkaši)
2. prerada ribljih proizvoda: prerada i konzerviranje ribe, rakova i mekušaca, gotova jela, proizvodnja ulja i masti te ostalih prehrambenih proizvoda
3. distribucija ribljih proizvoda: trgovina na malo ribom, rakovima i mekušcima u specijaliziranim prodavaonicama i trgovina na veliko ostalom hranom, uključujući ribu, rakove i mekušce.

Sektor neživih resursa dugi niz godina ima ključnu ulogu u smislu pružanja pristupa izvorima energije i sirovina potrebnih za europsko gospodarstvo. Iako su neki od njegovih podsektora sada dosegli zrelost i nalaze se u padu, očekuje se da će, prema Taksonomskom tehničkom izvješću grupe TEG (2019), sektor nastaviti igrati ključnu ulogu u prijelazu na održivu plavu ekonomiju, kako u smislu povećanja dostupnosti kritičnih materijala potrebnih za razvoj tehnologija s niskim udjelom ugljika i minimiziranje njegovih utjecaja na morski okoliš tako i ublažavanje klimatskih promjena uz usvajanje klimatski neutralnih, odgovornih i resursno učinkovitih pristupa.

Sektor plina i nafte u moru uglavnom je bio u padu tijekom proteklih nekoliko godina zbog smanjenja proizvodnje i rastućih troškova proizvodnje, kao i guranja prema čistoj energiji. Do 2022. godine, niske cijene nafte i trend prema alternativnim izvorima energije s nižim ugljičnim otiskom potkopavali su ekonomsku održivost *offshore* objekata. U EU-u, Ujedinjenom Kraljevstvu i Norveškoj, sve veći broj *offshore* naftnih i plinskih instalacija dolazi do kraja svog ekonomski produktivnog vijeka i ulazi u proces stavljanja izvan pogona. Prema Studiji razgradnje naftnih i plinskih postrojenja na moru Europske komisije (2022) za 2021. godinu, glavni razlozi za stavljanje naftnog ili plinskog polja izvan pogona su ili činjenica da se njegova proizvodnja smanjuje, što operativne troškove čini previsokim za održavanje daljnjeg rada, ili da tehnički uvjeti zahtijevaju zatvaranje i da se smatra neekonomičnim nadograditi infrastrukturu za nastavak proizvodnje preostalih resursa. Također se očekuje da će se razgradnja ubrzati zbog prelaska s fosilnih goriva na obnovljive i niskougljične izvore energije. Iako razgradnja u EU-u neće biti dovršena do najmanje 2050. godine, troškovi su

visoki i procjenjuje se da će u zemljama EU-27 biti potrošeno 48 milijardi eura na razgradnju naftne i plinske infrastrukture u razdoblju 2020. – 2030. godine.

Podsektor ostalih minerala i dalje je u porastu. Rudarstvo morskog dna identificirano je u europskoj strategiji „Plavi rast“ kao važna komponenta budućeg pomorskog gospodarstva, posebno za ispunjavanje zahtjeva visokotehnoloških industrija. Aktivnosti unutar Europe pretežno su usmjerene na vađenje morskih agregata, a ne na rudarske aktivnosti. Više od 50 milijuna m³ morskih agregata, pretežito pijeska i šljunka, vadi se iz europskog morskog dna, uglavnom za građevinsku industriju, uređenje plaža i izgradnju obrane mora (tj. za zaštitu dina, plaža, obalnih područja i otoka). Prema Izvješću Europske platforme za prostorno planiranje morskog područja (2023), najveći proizvođači agregata iz EU-a u 2018. godini bili su Nizozemska, Danska, Francuska i Belgija. Potražnja za resursima kao što su pijesak i šljunak, koji se koriste u građevinske svrhe i stvaranje betona, također će se vjerojatno povećati. Sve veća potražnja za pitkom vodom znači da se očekuje i porast desalinizacije. Isto tako, dok se obalne zajednice pokušavaju prilagoditi novim pritiscima izazvanim klimatskim promjenama, jaružanje, prihranjivanje plaža i obnavljanje pijeska mogu se intenzivirati.

Sektor neživih resursa sastoji se od triju glavnih podsektora, dalje raščlanjenih na aktivnosti:

1. nafta i plin: vađenje sirove nafte, vađenje prirodnog plina
2. ostali minerali: rad šljunčara i pješčara, vađenje gline i kaolina, također uključuje vađenje soli
3. pomoćne djelatnosti za vađenje nafte i prirodnog plina, ostalo rudarstvo i vađenje kamena.

Luke su bitna infrastruktura od velike komercijalne i strateške važnosti, a lučke su djelatnosti ključne za podržavanje slobodnog kretanja dobara i ljudi u Europi. Luke su važne za niz drugih sektora, uključujući, između ostalog, pomorski promet, brodogradnju i pomorsku obranu. One djeluju kao posrednici gospodarskog i trgovinskog razvoja. Mnoge europske luke važni su energetske i industrijske klasteri. Drugim riječima, luke olakšavaju klasteriranje energetskih i industrijskih poduzeća u njihovoj blizini. Bliska suradnja između luka, brodskih kompanija i ostalih sudionika u logističkom lancu nužna je kako bi se osigurao učinkovit i neometan protok tereta.

Lučke djelatnosti igraju ključnu ulogu u trgovini, gospodarskom razvoju i otvaranju radnih mjesta u Europi. Stoga se smatra zrelim i rastućim sektorom plave

ekonomije. Luke, kao prometna i logistička čvorišta s više djelatnosti, također igraju ključnu ulogu u razvoju postojećih i novih pomorskih sektora.

Sektor aktivnosti luka sastoji se od dvaju glavnih podsektora, koji su dalje raščlanjeni na sljedeće aktivnosti:

1. teret i skladištenje: rukovanje teretom i skladištenje
2. projekti luka i mora: izgradnja morskih objekata i uslužne djelatnosti povezane s morskim prometom.

Brodsko gospodarstvo bavi se proizvodnjom većih (uglavnom pomorskih) plovila namijenjenih trgovačkoj floti (teretni ili putnički prijevoz), *offshore* energetske industriji ili vojnim namjenama. Također uključuje proizvode i usluge isporučene za izgradnju, preinaku i održavanje brodova. Europska brodska industrija važna je iz gospodarske i društvene perspektive. Također, brodska industrija povezana je s drugim sektorima, uključujući promet, sigurnost, energiju, istraživanje i okoliš. Brodogradnja je važna i strateška industrija u nizu zemalja EU-a. Brodogradilišta značajno doprinose regionalnoj industrijskoj infrastrukturi i interesima nacionalne sigurnosti.

Brodsko gospodarstvo EU-a dinamičan je i konkurentan sektor. Prema Izvješću Europske komisije *EU Blue Economy Report 2023*, sektor ima tržišni udio od oko 6 % globalne knjige narudžbi u smislu kompenzirane bruto tonaže i 19 % u smislu vrijednosti; za pomorsku opremu, udio EU-a raste na 50 %, što EU čini glavnim igračem u globalnoj industriji brodogradnje. Europska brodska industrija trenutačno se sastoji od približno 300 brodogradilišta specijaliziranih za izgradnju i popravak najsloženijih i tehnološki najnaprednijih civilnih i mornaričkih brodova i platformi te druge opreme za pomorske primjene. Industrija obuhvaća otprilike 22 000 dobavljača opreme i servisnih tvrtki. Prema partnerstvima u okviru Pakta za vještine EU-a, godišnja vrijednost proizvodnje cjelokupnog opskrbnog lanca europske brodske industrije dosegla je ukupno 125 milijardi eura, stvarajući 576 000 izravnih radnih mjesta i dodatnih pola milijuna neizravnih radnih mjesta.

Sektor brodogradnje i remonta obuhvaća sljedeće podsektore i djelatnosti:

1. brodogradnja: gradnja brodova i plutajućih objekata, izgradnja brodova za razonodu i sport, popravak i održavanje brodova i čamaca
2. oprema i strojevi: proizvodnja užadi, konopa i mreža, proizvodnja tekstila (osim odjeće), proizvodnja sportske opreme, proizvodnja motora i turbina (osim zrakoplova) te proizvodnja instrumenata za mjerenje, ispitivanje i navigaciju.

Pomorski promet bitan je element globalne trgovine i gospodarstva te je, stoga, visoko globaliziran. Prema Izvješću Europske komisije *EU Blue Economy Report 2023*, u Europskoj uniji zaslužan je za 77 % vanjske trgovine i 35 % trgovine unutar EU-a. U 2020. godini brodovi registrirani pod zastavom države članice EU-a predstavljali su 16,2 % ukupne svjetske flote mjereno nosivošću (DWT). Putnički brodovi EU-a mogu prevesti do 1,3 milijuna putnika, što predstavlja 40 % kapaciteta svjetskog prijevoza putnika. U 2019. godini gotovo polovica pomorskog prometa u EU-u bila je isključivo brodovima na domaćim rutama, uglavnom zbog čestih prijelaza *roll-on, roll-off* putničkih brodova i trajekata. U lukama EU-a pretovareno je blizu četiri milijarde tona robe, što čini oko polovicu ukupne robe po težini kojom se trguje između zemalja EU-27 i Ujedinjenog Kraljevstva te ostatka svijeta. Stoga je pomorski promet važan stup plave ekonomije, dok, s druge strane, vrši pritisak na okoliš. Prema Izvješću o utjecaju na okoliš europskog pomorskog prometa za 2021. godinu emisije stakleničkih plinova, kao i onečišćenje zraka, posebno dušikovi i sumporni oksidi te čestice, iz pomorskog prometa i lučkih aktivnosti, doprinose globalnom zatopljenju, dovodeći, između ostalog, do povećanja ekstremnih vremenskih događaja i porasta razine mora.

Pomorski promet igra ključnu ulogu u svjetskom gospodarstvu i ima presudan doprinos dekarbonizaciji. Prema Izvješću Europske komisije *EU Blue Economy Report 2023*, brodski je način prijevoza prijevoz s najnižim udjelom ugljika i s najnižim emisijama ugljičnog dioksida (CO₂) po udaljenosti i prevezenoj težini. Međunarodni pomorski promet čini manje od 3 % godišnjeg globalnog CO₂ i proizvodi manje emisije ispušnih plinova, uključujući dušikove okside, ugljikovodike, ugljikov monoksid i sumporov dioksid, za svaku prevezenu tonu po kilometru od zračnog ili cestovnog prometa. Međutim, s obzirom na važnost pomorskog prometa i izgleda za povećanje pomorskog prometa, neophodno je da industrija nastavi smanjivati svoj utjecaj na okoliš.

Sektor pomorskog transporta uključuje sljedeće podsektore:

1. prijevoz putnika: pomorski i obalni prijevoz putnika i unutarnji vodni promet putnika
2. prijevoz robe: pomorski i obalni teretni promet i unutarnji vodni promet
3. usluge prijevoza: iznajmljivanje i zakup plovnih prijevoznih sredstava.

Ljepota, kulturno bogatstvo i raznolikost obalnih područja EU-a učinili su ih omiljenim odredištem za mnoge turiste iz Europe i inozemstva, čineći obalni i pomorski turizam važnim sektorom turizma. Prema podacima Europske

komisije o obalnom i pomorskom turizmu, više od 50 % krevetnih kapaciteta u hotelima diljem Europe koncentrirano je u regijama s morskom granicom. Obalni turizam najveći je rastući sektor u cijeloj plavoj ekonomiji u smislu bruto dodane vrijednosti i zaposlenosti. Kao što je opisano u europskoj strategiji „Plavi rast“, obalni i pomorski turizam nosi veliki potencijal za promicanje pametne, održive i inkluzivne Europe.

Europa je najposjećeniji kontinent na svijetu i čini polovicu svjetskih međunarodnih turističkih dolazaka. Samo EU čini gotovo 40 % međunarodnih dolazaka u svijetu. Obalna područja i otoci obično su glavna turistička žarišta. Ova su područja uvijek bila tražena zbog svojih jedinstvenih karakteristika, što ih čini idealnim mjestima za slobodno vrijeme i turističke aktivnosti. Posljednjih je godina sve veći broj turista doveo do zabrinutosti zbog ekoloških utjecaja turizma na morske ekosustave i održivi razvoj obalnih područja, posebno onih koje karakterizira visoka gustoća izgradnje i sve veći utjecaj na okoliš. Više od polovice turističkih smještajnih objekata u EU-u nalazi se u obalnim područjima.

Sektor obalnog turizma podijeljen je u tri glavna podsektora:

1. smještaj
2. prijevoz
3. ostali rashodi.

Navedeni su podaci promatrani u odnosu na bruto dodanu vrijednost po zaposleniku u sektorima plave ekonomije. Bruto dodana vrijednost po zaposleniku (BDV) je pokazatelj produktivnosti rada. Prema definiciji Europske unije, „BDV se definira kao vrijednost *outputa* u osnovnim cijenama umanjena za intermedijarnu potrošnju vrednovanu po kupovnim cijenama“.

3.2. METODOLOGIJA KORIŠTENA U ANALIZI

Dendrogram je dijagram hijerarhijskog stabla koji se koristi u analizi klastera za vizualizaciju odnosa između različitih podatkovnih točaka ili varijabli (Behr *et al.*, 1989). U kontekstu analize financijskih aspekata plave ekonomije, posebno u pogledu interakcije živih resursa, neživih resursa, lučkih aktivnosti, brodogradnje i popravka, pomorskog prometa, obalnog turizma i BDV-a (bruto dodane vrijednosti) po zaposleniku, dendrogram može ponuditi nekoliko značajnih prednosti navedenih kako slijedi:

1. Identificiranje klastera

Dendrogram omogućuje identifikaciju klastera povezanih varijabli ili sektora unutar financijskih aspekata plave ekonomije, što je ključno za razumijevanje načina na koji su različite komponente međusobno povezane i grupirane na temelju svojih financijskih karakteristika.

2. Vizualizacija odnosa

S pomoću dendrograma moguće je vizualno prikazati odnose (Earle, 2010) između navedenih financijskih aspekata. Duljina grana u dendrogramu odražava stupanj sličnosti ili različitosti između varijabli. Bliže grane ukazuju na jači odnos, dok udaljene grane ukazuju na manju sličnost.

3. Otkrivanje uzoraka

Metode klasteriranja, poput dendrograma, pomažu u otkrivanju obrazaca ili podskupina unutar financijskih aspekata plave ekonomije. To može otkriti skrivene strukture ili sličnosti koje možda neće biti odmah vidljive kada se pojedinačne varijable ispituju zasebno.

4. Razumijevanje ekonomskih međuovisnosti

Financijski aspekti plavog gospodarstva vjerojatno su međusobno ovisni. Dendrogram pomaže u razumijevanju kako su ti različiti aspekti povezani i kako utječu jedni na druge. Na primjer, može istaknuti postoje li jaki odnosi između pomorskog prometa i lučkih aktivnosti ili je li obalni turizam usko povezan sa živim resursima.

5. Olakšavanje donošenja odluka

Metode grupiranja daju uvide koji mogu voditi procese donošenja odluka (Masato *et al.*, 2022). Identificiranjem klastera kreatori politika, istraživači i zainteresirane strane u industriji mogu se usredotočiti na specifične skupine financijskih aspekata koji dijele sličnosti ili zahtijevaju slične intervencije.

6. Poboljšanje raspodjele resursa

Razumijevanje obrazaca klasteriranja može pomoći u optimiziranju raspodjele resursa. Ako su određeni financijski aspekti usko povezani, ulaganja ili politike usmjerene na jedan aspekt mogu imati učinke prelijevanja na druge unutar istog klastera.

7. Poboljšanje strategija specifičnih za sektor

Dendrogram može pomoći u formuliranju ciljanijih i učinkovitijih strategija (Brlečić Valčić *et al.*, 2022) za svaki sektor unutar plavog gospodarstva. Na pri-

mjer, ako se živi resursi i obalni turizam grupiraju zajedno, strategije za održivi razvoj u jednom sektoru mogu pozitivno utjecati na drugi.

8. Procjena ekonomske uspješnosti

Bruto dodana vrijednost (BDV) po zaposlenom ključan je pokazatelj ekonomske uspješnosti. Integracija u analizu dendrograma omogućuje sveobuhvatnu procjenu toga kako financijski aspekti doprinose ukupnoj ekonomskoj vrijednosti i kako zapošljavanje utječe na različite klastere.


Sumarno, korištenje dendrograma za analizu klasteriziranja u ispitivanju financijskih aspekata plave ekonomije daje snažan alat za razotkrivanje složenih odnosa i obrazaca (Van Sickle, 1997). Ne samo da pomaže u razumijevanju međuovisnosti između različitih sektora nego i usmjerava donošenje strateških odluka i formuliranje politike za održivi i ekonomski održivi razvoj.

U svrhu analize podataka za ovo istraživanje, svi su podaci prethodno standardizirani kako bi se postigle bolje karakteristike analize. U analizi je korišten programski paket Matlab.

4. REZULTATI I DISKUSIJA

Na Slici 1. prikazani su rezultati provedene analize.

Slika 1. Rezultati provedene analize



Izvor: izradili autori u programskom paketu Matlab

Iz provedene analize izvode se zaključci kako slijedi:

1. BDV po zaposlenom (7) u sektoru plave ekonomije direktno je vezan uz neto ulaganja u primarnoj proizvodnji (14), a primarna proizvodnja ovisna je o osobama zaposlenim u pomorskom transportu (5) i dodanoj vrijednosti po faktorskim troškovima u pomorskom transportu (12), što navodi na diskusiju:
 - *Kontekst međupovezanosti gospodarskih aktivnosti:* analiza naglašava međusobnu povezanost različitih gospodarskih aktivnosti unutar plave ekonomije. Učinkovit pomorski promet ne samo da utječe na dodanu vrijednost u procesu prijevoza nego i izravno utječe na ekonomsku uspješnost primarnih proizvodnih sektora.
 - *Kontekst ekonomske učinkovitosti i produktivnosti:* izravan odnos između BDV-a po zaposlenom i neto ulaganja u primarnu proizvodnju sugerira da su ekonomska učinkovitost i produktivnost u primarnoj proizvodnji pod utjecajem razine ulaganja u te aktivnosti. Time se naglašava važnost strateških ulaganja u održivi razvoj primarnih proizvodnih sektora.
 - *Kontekst dinamike lanca vrijednosti:* analiza naglašava dinamiku lanca vrijednosti unutar plavog gospodarstva, gdje pomorski promet služi kao kritična komponenta u povećanju ukupne vrijednosti izlaza primarne proizvodnje. Učinkovit transport doprinosi konkurentnosti i utrživosti proizvoda iz primarnih proizvodnih sektora.
 - *Kontekst potrebe za sveobuhvatnim strategijama:* kako bi optimizirali odnos koji proizlazi iz analize, kreatori politika, dionici u industriji i ulagači u plavu ekonomiju moraju usvojiti sveobuhvatne strategije. To uključuje razmatranje ne samo neto ulaganja u primarnu proizvodnju nego i aspekte učinkovitosti i dodane vrijednosti pomorskog prometa.
 - *Kontekst ravnoteže ekonomskih i ekoloških problema:* u fokusu na ekonomske pokazatelje, kao što su bruto dodana vrijednost po zaposleniku i neto ulaganje, bitno je ostati u ravnoteži s održivošću okoliša. Plavo gospodarstvo treba dati prednost praksi koja osigurava odgovorno i održivo korištenje morskih resursa.
2. S druge strane, BDV po zaposlenom (7) u sektoru plave ekonomije direktno je vezan uz osobe zaposlene u brodogradnji i remontu (4) te dodanoj vrijednosti po faktorskim troškovima u brodogradnji i remontu (11), što navodi na zaključke:

- *Kontekst produktivnosti rada i ekonomskog učinka:* interakcija sugerira da je BDV po zaposleniku u širem sektoru plavog gospodarstva pod utjecajem gospodarskih aktivnosti povezanih s brodogradnjom i remontom. Veći BDV po zaposlenom ukazuje na povećanje produktivnosti rada i ekonomske proizvodnje unutar plavog gospodarstva, uključujući segment brodogradnje i remonta.
 - *Kontekst utjecaja na zapošljavanje:* broj zaposlenih u brodogradnji i remontu izravno utječe na tržište rada unutar plavog gospodarstva. Što je veći broj zaposlenih pojedinaca, to je veći potencijal za pozitivne društveno-ekonomske učinke, uključujući stvaranje prihoda i razvoj vještina.
 - *Kontekst dodatne vrijednosti u procesima brodogradnje i remonta:* dodana vrijednost prema troškovima faktora u brodogradnji i remontu odražava učinkovitost i djelotvornost ovih procesa ukazujući na ekonomski doprinos ovih aktivnosti.
 - *Kontekst ekonomske otpornosti i inovativnosti:* visoki BDV po zaposleniku, zajedno sa značajnom radnom snagom i dodanom vrijednošću po faktorskim troškovima, sugerira otporan i inovativan sektor brodogradnje i remonta. To može pridonijeti ukupnoj konkurentnosti plavog gospodarstva poticanjem gospodarskog rasta, tehnološkog napretka i tržišne prilagodljivosti.
 - *Politički kontekst:* kreatori politika u plavom gospodarstvu trebali bi razmotriti ravnotežu između radno intenzivne brodogradnje te aktivnosti remonta i potrebe za tehnološkim inovacijama za povećanje dodane vrijednosti. Uspostavljanje te ravnoteže ključno je za održivi rast, mogućnosti zapošljavanja i konkurentnost.
 - *Implikacije ulaganja:* Ulagачi i dionici zainteresirani za plavo gospodarstvo, posebno u brodogradnji i remontu, trebali bi procijeniti te interakcije kako bi donosili valjane odluke. Razumijevanje odnosa između BDV-a, zaposlenosti i dodane vrijednosti pruža dragocjene uvide u ekonomsku održivost i potencijalne povrate ulaganja.
3. Indirektno, u okviru istog klastera, BDV po zaposleniku povezan je s osobama zaposlenima u sektoru neživih resursa plave ekonomije (2) koji ovisi o dodanoj vrijednosti po faktorskim troškovima vezanima uz područje neživih resursa (9) i neto ulaganjima u podsektoru nafte i plina (17), što navodi na sljedeće zaključke:

- *Kontekst međusobno povezanih ekonomskih čimbenika*: interakcija sugerira povezanost ekonomskih čimbenika unutar plave ekonomije. Na BDV po zaposlenom vjerojatno utječu ekonomske aktivnosti koje se odnose i na nežive resurse i na podsektor nafte i plina. Razumijevanje ove interakcije ključno je za razumijevanje cjelokupnog gospodarskog krajolika.
- *Dinamika tržišta rada*: broj osoba zaposlenih u sektoru neživih resursa ima implikacije na tržište rada unutar plave ekonomije. Ova radna snaga pridonosi ekonomskim aktivnostima povezanim s neživim resursima, a utjecaj na zapošljavanje može imati šire društveno-ekonomske implikacije.
- *Kontekst dodane vrijednosti*: dodana vrijednost prema faktorskim troškovima u sektoru neživih resursa odražava učinkovitost i djelotvornost ovih aktivnosti. Razmatra stvorenu ekonomsku vrijednost izvan izravnih troškova, ukazujući na doprinos sektora neživih resursa u plavoj ekonomiji.
- *Kontekst podsektora nafte i plina*: neto ulaganja u podsektor nafte i plina otkrivaju stupanj ovisnosti o ovoj specifičnoj industriji unutar plave ekonomije. Gospodarske aktivnosti povezane s naftom i plinom mogu značajno utjecati na BDV, zapošljavanje i dodatnu vrijednost u širem plavom gospodarstvu.
- *Kontekst održivosti*: procjena interakcije između BDV-a, zaposlenosti i ulaganja u naftu i plin također zahtijeva razmatranje održivosti. Usklađivanje gospodarskog rasta s ekološkim i društvenim aspektima ključno je za dugoročnu otpornost plavog gospodarstva.
- *Politički kontekst*: kreatori politike moraju pažljivo razmotriti međudjelovanje ovih ekonomskih čimbenika kada formuliraju politike povezane s plavom ekonomijom. Uspostavljanje ravnoteže između različitih sektora, posebice između neživih resursa i podsektora nafte i plina, ključno je za održivi razvoj.

Prethodno analizirani veliki klaster direktno je povezan s drugim klasterom u kojem dominira neto ulaganje u podsektoru distribucije ribljih proizvoda (16), koji ovisi o opremi i strojevima (21), a on pak o projektima luka (19). Neto ulaganja u projekte luka (19) ovise o kompleksnoj isprepletenosti, s jedne strane, osoba zaposlenih u obalnom turizmu (6) i dodanoj vrijednosti po faktorskim troškovima obalnog turizma (13), a, s druge strane, neto ulaganju u podsektoru

ru prerade ribljih proizvoda (15). Ova ulaganja (15) ovise o dodanoj vrijednosti po faktorskim troškovima u živim resursa (8) vezane uz osobe zaposlene u lučkim aktivnostima (3) i dodanoj vrijednosti po faktorskim troškovima aktivnosti luka (10) te osobama zaposlenim u sektoru plave ekonomije u području živih resursa, odnosno proizvodnju hrane (1). Ovaj dio analize navodi na zaključke kako slijedi:

- Opisana interakcija prikazuje zamršenu dinamiku unutar opskrbnog lanca plavog gospodarstva, posebno u kontekstu distribucije ribljih proizvoda. To uključuje kontinuiranu petlju ovisnosti u rasponu od obrade do distribucije i čimbenika koji utječu na svaku fazu.
- Veza između obalnog turizma i lučkih projekata naglašava važnost turizma ne samo kao gospodarskog sektora nego i kao katalizatora za razvoj infrastrukture i ulaganja u pomorske aktivnosti.
- Dodana vrijednost po faktorskim troškovima u različitim fazama opskrbnog lanca djeluje kao ekonomski multiplikator. Ulaganja i gospodarske aktivnosti u jednom sektoru odjekuju međusobno povezanom mrežom, utječu na druge sektore i pridonose ukupnom gospodarskom rastu.
- Sredstva za život povezana s ljudima zaposlenim u aktivnostima plave ekonomije, kao što su lučki projekti i prerada ribljih proizvoda, igraju ključnu ulogu u određivanju socioekonomskog učinka ovih aktivnosti. To uključuje razmatranja raspodjele prihoda, otvaranja radnih mjesta i dobiti zajednice.
- Kreatori politika i dionici moraju strateški planirati i uzeti u obzir zamršene odnose opisane prilikom formuliranja politika povezanih s plavom ekonomijom. Uravnoteženje ulaganja, zapošljavanja i dodane vrijednosti u svim sektorima ključno je za održiv i otporan gospodarski razvoj.

Uz oba analizirana klastera, zaseban se klaster sastoji od neto ulaganja u podsektor vezan uz ostale minerale (18) i brodogradnju (20). Podsektor minerala i brodogradnja međusobno su povezani opskrbnim lancem. Brodogradnja zahtijeva sirovine, uključujući razne minerale, za izgradnju plovila. Stoga, neto ulaganja u podsektor minerala mogu utjecati na dostupnost i cijenu materijala za brodogradnju. Neto ulaganja u oba sektora pod utjecajem su ovisnosti o resursima i sigurnosti. Osiguravanje stabilne opskrbe mineralima za brodogradnju ključno je za sigurnost i održivost brodograđevne industrije unutar šireg plavog gospodarstva.

Na oba sektora utječe tehnološki napredak. Inovacije u tehnologijama obrade minerala mogu utjecati na učinkovitost i ekološki otisak ekstrakcije i korištenja minerala. Slično tome, napredak u brodograđevnim tehnologijama može utjecati na konkurentnost i održivost brodograđevne industrije. Financijski aspekti obaju sektora podložni su dinamici globalnog tržišta. Oscilacije u potražnji za mineralima i brodovima, kao i promjene u obrascima međunarodne trgovine, mogu utjecati na gospodarski učinak ovih sektora unutar plavog gospodarstva EU-a. I vađenje minerala i brodogradnja vode računa o okolišu. Održive prakse i poštovanje ekoloških propisa sve su važniji u okviru plave ekonomije EU-a. Neto ulaganja u te sektore moraju biti usklađena s ekološkim ciljevima kako bi se osiguralo zdravlje morskih ekosustava. Neto ulaganja u minerale i brodogradnju doprinose otvaranju radnih mjesta i gospodarskom rastu. Mogućnosti zapošljavanja stvaraju se i u uzvodnim (rudarstvo) i u nizvodnim (prerada, brodogradnja) djelatnostima. Ekonomski uspjeh ovih sektora poboljšava ukupnu ekonomsku učinkovitost plavog gospodarstva.

5. ZAKLJUČAK

U zaključku ovog znanstvenog rada o financijskim aspektima plave ekonomije u Europskoj uniji, ističemo ključne spoznaje koje proizlaze iz analize različitih dimenzija ovog dinamičnog sustava. Uspješne inicijative plavog gospodarstva ističu nužnost uključenosti lokalne zajednice te postavljanje održivosti ekosustava kao prioriteta, čime se stremi ravnoteži između ekonomske, društvene i ekološke dimenzije. Plava ekonomija aktivno teži razvoju tehnologija inspiriranih prirodom, koje ne samo da podržavaju ekonomske aktivnosti nego i održivo zadovoljavaju osnovne ljudske potrebe. Utemeljena na načelima ekosustava, plava ekonomija nastoji osigurati ekološku održivost u morskom i obalnom turizmu. Analiza odnosa između BDV-a po zaposleniku, neto ulaganja u primarnu proizvodnju te ključne uloge pomorskog prometa u dodavanju vrijednosti ukupnim gospodarskim aktivnostima unutar plavog gospodarstva ukazuje na potrebu strateškog planiranja i koordiniranih napora. Ovi sektori međusobno su povezani, a njihova sinergija ključna je za poticanje održivog i financijski održivog rasta u plavoj ekonomiji. Interakcija između BDV-a po zaposleniku, zaposlenih u brodogradnji i remontu te dodane vrijednosti po faktorskim troškovima u brodogradnji i remontu ilustrira kompleksnost dinamike rada i stvaranja ekonomske vrijednosti. Razumijevanje ovih odnosa ključno je za poticanje održivog rasta, maksimiziranje mogućnosti zapošljavanja i promicanje inovacija u brodogradnji i aktivnostima remonta. Odnos

između BDV-a po zaposleniku, osoba zaposlenih u sektoru neživih resursa, dodane vrijednosti po faktorskim troškovima povezanim s neživim resursima i neto ulaganja u podsektor nafte i plina naglašava kompleksnost ekonomske dinamike unutar plave ekonomije. Informirane političke odluke, poticanje održivog rasta i rješavanje izazova koji proizlaze iz ovih interakcija zahtijevaju duboko razumijevanje ovih veza.

Konačno, kompleksnost plave ekonomije zahtijeva holističke i integrirane pristupe politikama i ekonomskom planiranju kako bi se osigurali održivost i uspjeh plavog gospodarstva u cjelini. Veza između neto ulaganja u podsektor koji se odnosi na ostale minerale i brodogradnju reflektira međuovisnost različitih komponenti unutar plavog gospodarstva, naglašavajući važnost strateškog planiranja, tehnoloških inovacija, upravljanja okolišem i koherentnosti politika za optimizaciju ekonomskih koristi uz osiguravanje održivosti ovih sektora unutar okvira plavog gospodarstva EU-a. Kao ograničenja ovog istraživanja mogu se navesti ona vezana uz vremenski okvir promatranih podataka, što može utjecati na dinamiku promjena te složenost sektora unutar plave ekonomije, jer ista uključuje različite sektore s različitim karakteristikama, što može otežati stvaranje jedinstvenog modela analize koji obuhvaća sve relevantne dimenzije, kao i ograničenja vezana uz samu definiciju pojma plave ekonomije. Naime, pojmovi poput „održivosti“ ili „ekonomske vrijednosti“ mogu imati različite interpretacije, ovisno o perspektivi promatrača, što može utjecati i na interpretaciju rezultata.

Za daljnja istraživanja preporučuje se dublja analiza sektora. Istraživanje može biti prošireno dubljom analizom pojedinih sektora unutar plave ekonomije kako bi se dobile specifičnije informacije o financijskim aspektima i dinamici svakog sektora. Također, uvođenje međunarodne usporedbe financijskih aspekata plave ekonomije može pridonijeti boljem razumijevanju razlika i sličnosti između zemalja članica EU-a. Daljnje istraživanje može uključivati procjenu društvenih učinaka financijskih strategija plave ekonomije, uključujući aspekte poput zapošljavanja, socijalne uključenosti i ravnoteže između različitih društvenih skupina. Nadalje, razvoj modela koji integrira ekonomske, ekološke i društvene aspekte može pridonijeti boljem razumijevanju održivosti financijskih strategija plave ekonomije. Osim toga, fokusiranje na istraživanje konkretnih inovacija inspiriranih prirodom u plavoj ekonomiji te njihov utjecaj na financijske rezultate može donijeti dodatne uvide. Valjalo bi također uložiti napore za analizu regulatornog okvira koji podržava ili ograničava financijske strategije plave ekonomije, što može biti korisno za oblikovanje preporuka za unapređenje.

REFERENCE

1. Bari, A. (2017) Our Oceans and the Blue Economy: Opportunities and Challenges, *Procedia Engineering*, Vol. 194, str. 5-11. Dostupno na: <https://doi.org/10.1016/J.PROENG.2017.08.109>
2. Behr, J., Smit, C.F. i Groenewald, J.A. (1989) Note: the dendrogram: an exploratory technique for analysis of quantitative and qualitative data sets, *Agrekon*, Dostupno na: <https://doi.org/10.1080/03031853.1989.9525101>
3. Biukšāne, I. (2022) Blue Economy in the EU-27. *Journal of Economics Studies and Research*, Vol. 2022, str. <https://doi.org/10.5171/2022.943474>
4. Brlečić Valčić, S., Peša, A., i Čičin-Šain, D. (2022) Analysis of the Eurozone's Resilience to Crises and Disturbances in the Context of EU Development Strategies—Contemporary Approach Using Anfis, *Sustainability*, Vol. 14(23), 15594. Dostupno na: <https://doi.org/10.3390/su142315594>
5. Camarero Orive, A., González-Cancelas, N., Cabrero, J., i Santiago, J. (2022) Use of a Delphi Panel to Determine the Degree of Implementation of Blue Economy in Spanish Ports, *Journal of Marine Science and Engineering*, Vol. 10(11), 1573. Dostupno na: <https://doi.org/10.3390/jmse10111573>
6. Cisneros-Montemayor, A., Moreno-Báez, M., Voyer, M., Allison, E., Cheung, W., Hessing-Lewis, M., Oyinlola, M., Singh, G., Swartz, W., i Ota, Y. (2019) Social equity and benefits as the nexus of a transformative Blue Economy: A sectoral review of implications, *Marine Policy*, Vol. 109, 103702. Dostupno na: <https://doi.org/10.1016/j.marpol.2019.103702>
7. Costa, J., Freitas, B., Lisbôa, C., Santos, T., Brusch, L., i Morais, M. (2019) Microalgal biorefinery from CO₂ and the effects under the Blue Economy. *Renewable and Sustainable Energy Reviews*, Vol. 99, str. 58-65. Dostupno na: <https://doi.org/10.1016/J.RSER.2018.08.009>
8. Das, J. (2023) Blue Economy, Blue Growth, Social Equity and Small-scale Fisheries: A Global and National Level Review, *Studies in Social Science Research*, Vol. 4 (1). Dostupno na: <https://doi.org/10.22158/sssr.v4n1p38>
9. Doyle, T. (2018) Blue Economy and the Indian Ocean Rim, *Journal of the Indian Ocean Region*, Vol. 14, str. 1-6. <https://doi.org/10.1080/19480881.2018.1421450>
10. Earle, D. (2010) Dendrogram seriation in data visualisation: algorithms and applications (Doctoral dissertation, National University of Ireland, Maynooth (Ireland)).
11. EU Technical Expert Group (TEG) on Sustainable Finance. Financing a sustainable European economy. Taxonomy technical report. June 2019. Dostupno na: https://finance.ec.europa.eu/system/files/2019-06/190618-sustainable-finance-teg-report-taxonomy_en.pdf
12. European Commission. Coastal and maritime tourism. Dostupno na: https://ec.europa.eu/growth/sectors/tourism/offer/maritime-coastal_en
13. European Environmental Agency (EEA). European Maritime Transport Environmental Report 2021. Publications Office of the European Union, 2021. Dostupno na: <https://www.eea.europa.eu/publications/maritime-transport>

14. Taxonomy: Final report of the Technical Expert Group on Sustainable Finance (2020). EU Technical Expert Group on Sustainable Finance. Dostupno na: https://finance.ec.europa.eu/system/files/2020-03/200309-sustainable-finance-teg-final-report-taxonomy_en.pdf
15. Jacob, A., i Umoh, O. (2022) The Nigerian blue economy: economic expansion issues and challenges, *Socio Economy And Policy Studies*, Vol. 2(1), str. 29-33. Dostupno na: <https://doi.org/10.26480/seps.01.2022.29.33>
16. Kathijotes, N. (2013) Keynote: Blue economy - environmental and behavioural aspects towards sustainable coastal development, *Procedia - Social and Behavioral Sciences*, Vol. 101, str. 7-13. Dostupno na: <https://doi.org/10.1016/J.SBSPRO.2013.07.173>
17. Lee, K., Noh, J., Lee, J., i Khim, J. (2021) Blue economy and the total environment: Mapping the interface, *Environment international*, Vol. 157, 106796. Dostupno na: <https://doi.org/10.1016/j.envint.2021.106796>
18. Link, J., Thébaud, O., Smith, D., Smith, A., Schmidt, J., Rice, J., Poos, J., Pita, C., Lipton, D., Kraan, M., Frusher, S., Doyen, L., Cudennec, A., Criddle, K., i Bailly, D. (2017) Keeping Humans in the Ecosystem, *ICES Journal of Marine Science*, Vol. 74, str. 1947-1956. Dostupno na: <https://doi.org/10.1093/icesjms/fsx130>
19. Maritime in Croatia Market Overview 2023-2027 (2023) Market Overview Report. Dostupno na: <https://www.reportlinker.com/market-report/Maritime/664575>
20. Masato, Ota, Sakurai Yuko, and Oyama Satoshi. (2022) Coalitional Game Theoretic Federated Learning.. Proceedings of the 21st IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology (WI-IAT 2022).
21. Okafor-Yarwood, I., Kadagi, N. I., Miranda, N. A., Uku, J., Elegbede, I. O., i Adewumi, I. J. (2020) The blue economy-cultural livelihood-ecosystem conservation triangle: The African experience, *Frontiers in Marine Science*, Vol. 7, 586. Dostupno na: <https://doi.org/10.3389/fmars.2020.00586>
22. Pauli, G. (2021) The Blue Economy, *International Economic Law*. Dostupno na: <https://umrah.ac.id/en/archives/8075>
23. Quote from SEA Europe and IndustriAll Europe. Commitment made under the EU Pact for Skills. Upskilling shipbuilding and maritime technology workers in Europe. Dostupno na: <https://ec.europa.eu/social/BlobServlet?docId=24825&langId=en>
24. Report of the European Commission (2021) Study on Decommissioning of offshore oil and gas installations: a technical, legal and political analysis. Dostupno na: <https://op.europa.eu/en/publication-detail/-/publication/7d7d51a5-8d44-11ec-8c40-01aa75ed71a1/language-en>
25. Report of the European MSP Platform for the European Commission (2018). Technical Study: MSP as a tool to support Blue Growth. Sector Fiche: Marine Aggregates and Marine Mining. Based on EMODnet database. Dostupno na: https://maritime-spatial-planning.ec.europa.eu/sites/default/files/roundtable_discussion_paper_oil_gas_final.pdf
26. Sarker, S., Hussain, F., Assaduzzaman, M., i Failler, P. (2019) Blue Economy and Climate Change: Bangladesh Perspective, *Journal of Ocean and Coastal Economics*, Vol. 6(2), 6. Dostupno na: <https://doi.org/10.15351/2373-8456.1105>

27. Schutter, M., Hicks, C., Phelps, J., i Waterton, C. (2021) The blue economy as a boundary object for hegemony across scales, *Marine Policy*, Vol. 132, 104673. Dostupno na: <https://doi.org/10.1016/J.MARPOL.2021.104673>
28. Stanca, C., Olteanu, A., i Stinga, V. (2018) The labor market in the Blue Economy, *Journal of Physics: Conference Series*, Vol. 1122. Dostupno na: <https://doi.org/10.1088/1742-6596/1122/1/012026>
29. Sverdan, M. (2021) The Blue Economy: A New Trend in Social Development, *Green, Blue and Digital Economy Journal*, Vol. 2(3), str. 49-56. Dostupno na: <https://doi.org/10.30525/2661-5169/2021-3-8>
30. Tegar, D., i Gurning, R. O. S. (2018) Development of marine and coastal tourism based on blue economy, *International Journal of Marine Engineering Innovation and Research*, Vol. 2(2). Dostupno na: <https://doi.org/10.12962/J25481479.V2I2.3650>
31. The EU blue economy report (2023). European Commission. Dostupno na: <https://op.europa.eu/en/publication-detail/-/publication/9a345396-f9e9-11ed-a05c-01aa75ed71a1>
32. Van Sickle, J. (1997) Using mean similarity dendrograms to evaluate classifications, *Journal of Agricultural, Biological, and Environmental Statistics*, Vol. 2(4), str. 370-388. Dostupno na: <https://doi.org/10.2307/1400509>
33. Voyer, M., Benzaken, D., i Rambourg, C. (2022) Institutionalizing the Blue Economy: an examination of variations and consistencies among Commonwealth countries, *Philosophical Transactions of the Royal Society B*, Vol. 377. Dostupno na: <https://doi.org/10.1098/rstb.2021.0125>
34. Zhang, Y., Zhang, J., Liang, Y., Li, H., Li, G., Chen, X., Zhao, P., Jiang, Z., Zou, D., Liu, X., i Liu, J. (2017) Carbon sequestration processes and mechanisms in coastal mariculture environments in China, *Science China Earth Sciences*, Vol. 60, str. 2097-2107. Dostupno na: <https://doi.org/10.1007/s11430-017-9148-7>
35. Zsifkovits, M., Barbeito, G., Pickl, S., i Pauli, G. (2016) System Dynamics Modeling for Analyzing Business Model Innovation, *2016 5th IIAI International Congress on Advanced Applied Informatics (IIAI-AAI)*, str. 749-754. Dostupno na: <https://doi.org/10.1109/IIAI-AAI.2016.89>

FINANCIAL ASPECTS OF THE BLUE ECONOMY WITHIN THE EU PERSPECTIVE

Associate Professor Sonja Brlečić Valčić, PhD

University of Zadar, Department of Economics

e-mail: sbrlecicv@unizd.hr

Marijana Jerić, MEcon

University of Zadar, Department of Economics

e-mail: mjeric@unizd.hr

Assistant Professor Jurica Bosna, PhD

University of Zadar, Department of Economics

e-mail: jbosna@unizd.hr

ABSTRACT

In this paper, the authors explore the intricate financial aspects of the blue economy within the European Union (EU). By analysing investments, economic impacts, challenges, and political implications, the study sheds light on the financial sustainability of the EU's blue economy. Using hierarchical clustering analysis of selected EU member states, the study highlights relationships among individuals employed in the blue economy sector, value added per factor cost, net investments, and gross value added. The observed subsectors include primary production, non-producing activities, ports, shipbuilding, maritime transport, and coastal tourism. The analysis results emphasize that strategic planning and coordinated efforts in these interconnected sectors are crucial for promoting sustainable and economically viable growth in the blue economy. Understanding the interrelations among the observed sectors and categories is crucial for fostering sustainable growth, maximizing employment opportunities, and promoting innovation.

Keywords: Blue economy, value added, net investments, strategic planning, financial sustainability

JEL classification: E02, E23, E23, Q56

UTJECAJ INFLACIJE NA CIJENE DIONICA U REPUBLICI HRVATSKOJ

izv. prof. dr. sc. Dražen Koški

Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku
e-mail: dkoski@efos.hr

SAŽETAK

U ovome radu cilj je bio istražiti utjecaj inflacije na cijene dionica u Republici Hrvatskoj. U tu svrhu provedena je analiza vremenskih nizova koja je obuhvatila razdoblje od siječnja 2010. do listopada 2023. Inflacija je pritom mjerena indeksom potrošačkih cijena, a cijene dionica indeksom cijena dionica Zagrebačke burze – CROBEX-om. Analiza je provedena na dva načina. Prvo, provedeno je testiranje kointegracije između indeksa potrošačkih cijena i CROBEX-a kako bi se uočila možebitna dugoročna povezanost između ovih varijabli. Testiranje kointegracije provedeno je Johansеноvom metodologijom. Drugo, testirano je uzrokuje li jedna varijabla drugu u Grangerovu smislu. Pritom je primijenjen standardni test Grangerove uzročnosti i test Grangerove uzročnosti temeljen na bootstrap metodi. Rezultati istraživanja pokazali su da ne postoji dugoročna povezanost između inflacije i cijena dionica. Isto tako, nijedna varijabla ne uzrokuje drugu u Grangerovu smislu.

Ključne riječi: inflacija, CROBEX, kointegracija, Grangerova uzročnost, bootstrap metoda

JEL klasifikacija: C32, E31, G10

1. UVOD

Cilj ovoga rada jest istražiti utjecaj inflacije na cijene dionica u Republici Hrvatskoj. Ključno je pitanje je li ovaj utjecaj pozitivan ili negativan. Drugim riječima, utječe li inflacija na rast cijena dionica ili na njihov pad? No, općenito gledajući, ako je ovaj utjecaj u promatranom razdoblju alternirao ili je inflacija bila niska, možda ga ekonometrijski neće biti moguće opaziti.

Intuitivno, rast inflacije može utjecati na rast cijena dionica jer investitori žele zaštititi svoju kupovnu moć pa povećavaju potražnju za realnim dobrima. S obzirom na to da je dionica potvrda o vlasništvu nad realnim dobrom, rast potražnje za dionicama ima za posljedicu rast cijena tih dionica. S druge strane, u uvjetima postojanja poreza na zaradu od dionica, rast inflacije značit će pad realnoga prinosa dionice, pa će investitori biti skloni platiti manje za takvu dionicu.

Općenito gledajući, pozitivnu ili negativnu povezanost inflacije s cijenom dionica moguće je analizirati na temelju standardnoga izraza za određivanje cijene dionice (vidjeti na primjer u: Rose i Marquis, 2008, str. 182):

$$\text{Cijena dionice} = \sum_{t=0}^{\infty} \frac{E(D_t)}{(1+r)^t} \quad (1)$$

gdje je:

$E(D_t)$ = očekivana dividenda u vremenu t ,

r = tražena stopa prinosa.

Iz izraza (1) vidljivo je da je cijena dionice u pozitivnom odnosu s očekivanim budućim dividendama $E(D_t)$, a u negativnom odnosu s rizikom povezanim s tvrtkom koja isplaćuje te dividende. Dakle, što je veći rizik investiranja u promatranu tvrtku, veća će biti tražena stopa prinosa r . S obzirom na to da su dividende funkcija dobiti nakon oporezivanja, cijene dionica neizravno ovise o ovoj dobiti. U kontekstu izraza (1), kako navode Rose i Marquis (2008, str 182-183), na pitanje povećava li inflacija cijenu dionica ili je smanjuje, moguće je odgovoriti ovisno o tome je li inflacija potpuno očekivana od svih sudionika na tržištu ili nije. U slučaju da je inflacija potpuno očekivana, prihodi i rashodi tvrtke rast će jednakom brzinom pa će dobit i dividende ostati nepromijenjeni. No, u slučaju kad inflacija nije u potpunosti očekivana, ona će utjecati na promjenu dobiti i dividenda. Na primjer, ako je tvrtka ugovorila fiksne cijene sa svojim dobavljačima, rast inflacije značit će rast prihoda i kao rezultat toga, rast dobiti. No, ako je tvrtka ugovorila fiksne cijene s kupcima, rast inflacije za posljedicu će imati rast rashoda i pad dobiti.

Doprinos ovoga rada znanosti jesu zaključci proizašli iz rezultata provedene ekonometrijske analize utjecaja inflacije na dionički indeks u Republici Hrvatskoj. Ekonometrijska analiza, preciznije analiza vremenskih nizova, obuhvatila je oblikovanje empirijskoga modela – bivarijantnog neograničenog vektorskog autoregresivnog modela i, uvažavajući taj model, testiranje kointegracije Johansenovom metodologijom, testiranje uzročnosti standardnim Grangerovim

testom i Grangerovim testom temeljenim na *bootstrap* metodi. Rezultati istraživanja pokazali su da nema dugoročne povezanosti između inflacije i dioničkog indeksa u Republici Hrvatskoj niti da jedna varijabla uzrokuje drugu u Grangerovu smislu.

Struktura rada jest sljedeća. Nakon uvoda, u drugom poglavlju prikazan je pregled literature. U trećem poglavlju opisana je ekonometrijska metodologija korištena u radu. Podaci korišteni u radu opisani su u četvrtom poglavlju. U istom poglavlju prikazani su i rezultati istraživanja. Na kraju rada, u petom poglavlju, dan je zaključak.

2. PREGLED LITERATURE

Kao što je navedeno, utjecaj inflacije na cijene dionica može biti pozitivan ili negativan. Pozitivan utjecaj istaknuo je poznati klasični ekonomist Irving Fisher krajem 19. stoljeća (Fisher, 1896). On opisuje situaciju u kojoj se investitori žele zaštititi od rizika inflacije kupovinom realnih dobara. Naime, ako očekuju inflaciju, investitori će pokušati zaštititi svoju realnu kupovnu moć od propadanja. To mogu učiniti, između ostaloga i kupnjom dionica koje i predstavljaju potvrde o vlasništvom nad realnom imovinom – tvrtkom. Zbog rasta potražnje za dionicama, rast će i njihova cijena.

Modigliani i Cohn (1979) tvrde da investitori pate od novčane iluzije i da zbog toga cijene dionica na tržištu ne odražavaju njihovu stvarnu vrijednost. Drugim riječima, investitori čine pogrešku prilikom vrjednovanja dionica tako što u inflatornim vremenima koriste nominalnu kamatnu stopu, a ne realnu. Na ovaj način investitori sustavno podcjenjuju tržište dionica.

Ipak, ne slažu se svi s hipotezom novčane iluzije. Geske i Roll (1983, str. 4) ističu da je ona u suprotnosti s racionalnim očekivanjima i tržišnom efikasnošću, a Pindyck (1984, str. 335) smatra da je teško vjerovati da ova hipoteza može dugo opstati, osobito tijekom desetljeća visoke inflacije.

Feldstein (1980) ističe da nije ni potrebno razmatrati hipotezu novčane iluzije u kontekstu analize inverznog odnosa između cijena dionica i inflacije. On je pokazao da će u uvjetima postojanja poreza na zaradu od dionica i fiksne nominalne porezne stope rast inflacije prouzročiti višu efektivnu poreznu stopu, što će za posljedicu imati pad realnog prinosa dionica. U takvim uvjetima, investitori će biti manje skloni kupovati dionice pa će njihova cijena pasti.

Fama (1981) tvrdi da je povezanost između prinosa na dionice i inflacije lažna i da je rezultat drugih dviju povezanosti: povezanosti između realnih dioničkih prinosa i očekivane realne gospodarske aktivnosti i povezanosti između očekivane realne gospodarske aktivnosti i očekivane inflacije. Drugim riječima, pad realnih dioničkih prinosa u pozitivnom je odnosu s padom očekivane gospodarske aktivnosti, a pad očekivane gospodarske aktivnosti vodi prema rastu inflacije. Geske i Roll (1983) tvrde da je pad gospodarske aktivnosti povezan s padom naplate poreza i višim proračunskim deficitom. Monetizacija tog deficita za posljedicu će imati rast inflacije.

U Republici Hrvatskoj empirijska istraživanja o utjecaju inflacije na cijene dionica nisu brojna. Barbić i Čondić-Jurkić (2011) u kontekstu povezanosti makroekonomskih varijabli i burzovnih indeksa u odabranim zemljama srednje i istočne Europe pokazuju da ne postoji Grangerova uzročnost između inflacije i cijena dionica u Republici Hrvatskoj.

Hsing (2011) je istraživao utjecaj makroekonomskih varijabli na cijene dionica u Republici Hrvatskoj primjenom eksponencijalnog općeg autoregresivnog heteroskedastičnog (*exponential general autoregressive conditional heteroskedastic* – EGARCH) modela (Nelson, 1991). On je pokazao da postoji inverzan odnos između inflacije i cijena dionica.

Arnerić i Vladović (2021) koriste panel podatke i procjenitelj fiksnog efekta korigiran za pristranost (*bias-corrected least-squares dummy variable* – LSDV), (Bruno, 2005) kako bi istražili povezanost makroekonomskih varijabli i cijena dionica u Republici Hrvatskoj. Rezultati njihova istraživanja pokazuju da inflacija ima pozitivan utjecaj na cijene dionica.

3. EKONOMETRIJSKA METODOLOGIJA

S obzirom na to da je cilj ovoga rada istražiti postoji li utjecaj inflacije na dionički indeks u Republici Hrvatskoj, najprije su provedeni testovi jediničnih korijena u vremenskim nizovima promatranih varijabli. To su Phillips-Perro-nov test (Phillips i Perron, 1988) i Schmidt-Phillipsov test (Schmidt i Phillips, 1992). Naime, Sims, Stock i Watson (1990) pokazali su da standardni Grangerov test uzročnosti (Granger, 1969) nije moguće primijeniti u uvjetima nestacionarnih varijabli jer ima nestandardnu asimptotsku distribuciju. No, ako varijable imaju jedinični korijen, moguće je primijeniti Grangerov test uzročnosti temeljen na *bootstrap* metodi koju je razvio Efron (1979). Isto tako, line-


arna kombinacija nestacionarnih varijabli može biti stacionarna pri čemu je riječ o kointegraciji. U slučaju postojanja kointegracije, moguće je primijeniti standardni Grangerov test uzročnosti uz uvažavanje reziduala modela korekcije pogreške (*error correction model* – ECM). Testiranje kointegracije provedeno je Johansenovim pristupom kointegriranom vektorskom autoregresivnom (*cointegrated vector autoregressive* – CVAR) modelu (Johansen 1988, Johansen 1991, Johansen 1992, Johansen 1994, Johansen 1995, Johansen i Juselius 1990, Johansen i Juselius 1992, Johansen i Juselius 1994). U tu svrhu prvo je oblikovan bivarijantni neograničeni vektorski autoregresivni model (*unrestricted vector autoregressive* – UVAR), a zatim je proveden Johansenov test traga matrice svojstvenih vrijednosti – λ_{trace} test. Budući da hipoteza kointegracije varijabli u ovome radu nije prihvaćena, vremenski nizovi varijabli diferencirani su kako bi se postigla njihova stacionarnost. Nakon toga, ponovno je procijenjen bivarijantni neograničeni vektorski autoregresivni model, proveden je standardni Grangerov test uzročnosti i Grangerov test uzročnosti temeljen na *bootstrap* metodi.

4. PODACI I REZULTATI ISTRAŽIVANJA

Kao pokazatelj cijena dionica, u ovome radu korišten je dionički indeks CROBEX (u nastavku ekonometrijske analize LNCROBEX), a kao pokazatelj inflacije korišten je indeks potrošačkih cijena (u nastavku ekonometrijske analize LNCPI). Podaci o CROBEX-u preuzeti su s internetske stranice Zagrebačke burze, a podaci o indeksu potrošačkih cijena preuzeti su iz baze podataka Hrvatske narodne banke. Podaci se odnose na razdoblje od siječnja 2010. do listopada 2023 godine. S obzirom na to da je indeks potrošačkih cijena na mjesečnoj razini, a CROBEX je na dnevnoj, za potrebe ovoga istraživanja izračunana je aritmetička sredina CROBEX-a na mjesečnoj razini. Svi su podaci logaritamski transformirani i sezonski neprilagođeni.

Na Slici 1. prikazane su spomenute varijable u razinama i prvim diferencijama. Obje varijable u razinama izgledaju nestacionarno, a približno stacionarno u diferencijama. Iako su grafički prikazi korisni, zbog moguće subjektivnosti istraživača, za donošenje konačnoga zaključka o nestacionarnosti promatranih varijabli potrebno je provesti formalne testove.

Slika 1. Varijable u razinama i diferencijama



Izvor: autorova izrada

U Tablici 1. prikazani su rezultati dvaju testova jediničnih korijena, Phillips-Perronova testa (Phillips i Perron, 1988) i Schmidt-Phillipsova testa (Schmidt i Phillips, 1992). Oba testa ne odbacuju nul hipotezu o postojanju jediničnog korijena u varijablama LNCROBEX i LNCPI u razinama. Isto tako, nakon diferenciranja ovih varijabli (sada označenih s DLNCROBEX i DLNCPI) oba testa odbacuju nul hipotezu o njihovoj nestacionarnosti.

Tablica 1. Phillips-Perronov i Schmidt-Phillipsov test jediničnih korijena

Varijabla Pomaci		Phillips-Perronov test		Schmidt-Phillipsov test	
		Statistika	Pomaci	Statistika	
LNCROBEX	Konstanta	4	-2,56768	-	-
LNCROBEX	Konstanta; Trend	4	-2,71206	4	-2,925
LNCPI	Konstanta	4	2,92171	-	-
LNCPI	Konstanta; Trend	4	1,35497	4	-0,851
DLNCROBEX	Konstanta	4	-9,45254**	-	-
DLNCROBEX	Konstanta; Trend	4	-9,52758**	4	-8,189**
DLNCPI	Konstanta	4	-6,90788**	-	-
DLNCPI	Konstanta; Trend	4	-7,14156**	4	-6,275**

Izvor: autorov izračun

Napomena: pomaci su izračunani primjenom Schwertove metode (Schwert, 1989). ** označuje značajnost na razini 1 %

Da bi se testirala kointegracija Johansenovim pristupom, bilo je potrebno najprije oblikovati UVAR model. U ovome slučaju, korištenjem Schwarzova Bayesijskoga kriterija (*Schwarz Bayesian criterion* – SBC), Hannan-Quinova kriterija (*Hannan-Quin criterion* – HQC) te uvažavanjem testova pogrešne specifikacije modela odabran je model s dva pomaka. Sezonski utjecaji obuhvaćeni su primjenom centriranih sezonskih *dummy* varijabli, a u model je uključen i trend s obzirom na to da je on očito prisutan u promatranim varijablama. S obzirom na početnu nenormalnost reziduala u modelu i postojanje triju netipičnih vrijednosti (*outliers*) u modelu (vrijednosti standardiziranih reziduala modela većih od 3,3 standardne devijacije) u model su uvrštene tri tranzitorne *dummy* varijable na način koji su opisali Hendry i Juselius (2001). Nakon toga, provedeni su testovi pogrešne specifikacije UVAR modela. Rezultati ovih testova prikazani su u Tablici 1. i jasno ukazuju na to da ne treba odbaciti nul hipoteze o nepostojanju autokorelacije i nenormalnosti reziduala. P-vrijednost za multivarijantni test autoregresivne uvjetne heteroskedastičnosti (ARCH) iznosi 0,049, no Rahbek i ostali (2002) pokazali su da je test kointegracije robustan na umjerene ARCH utjecaje. Nakon oblikovanja UVAR modela, proveden je test traga matrice svojstvenih vrijednosti – λ_{trace} test. No, s obzirom na to da UVAR model sadrži *dummy* varijable, bilo je potrebno simulirati asimptotsku distribuciju ovoga testa. Rezultati simulacije prikazani su u Tablici 3. Iz Tablice 3. vidljivo je da ne postoji kointegracija između promatranih varijabli pa je UVAR model prihvatljivo oblikovati u prvim diferencijama. Da bi se očuvala konzistentnost ekonometrijske analize, sve determinističke varijable, centrirane sezonske *dummy* varijable, tranzitorne *dummy* varijable i trend, ostavljene su u modelu.

Tablica 2. Testovi pogrešne specifikacije neograničenoga VAR modela (LNCROBEX, LNCPI)

Multivarijantni testovi:		
Test autokorelacije		
LM(1)	Hi-kvadrat (4) = 4,850 [0,303]	
Test normalnosti	Hi-kvadrat (4) = 2,043 [0,728]	
Test autoregresivne uvjetne heteroskedastičnosti (ARCH)		
LM(1)	Hi-kvadrat (9) = 17,011 [0,049]	
Univarijantni testovi:		
	DLNCROBEX	DLNCPI
Asimetrija – treći moment	0,147	0,203
Zaobljenost – četvrti moment	3,208	3,084
ARCH	12,510 [0,002]	2,548 [0,280]
Jarque-Bera	1,356 [0,508]	1,332 [0,514]
R ²	0,487	0,733

Izvor: autorov izračun

Napomena: P-vrijednosti su u uglatim zagrada

U Tablici 4. prikazani su rezultati testova pogrešne specifikacije UVAR modela koji sadrži promatrane varijable u prvim diferencijama. Rezultati testova

Tablica 3. Simulacija asimptotske distribucije testa traga matrice svojstvenih vrijednosti – λ_{trace} testa

Broj replikacija (N): 10 000						
Dužina slučajnih hodova (T): 400						
I(1) analiza						
p-r	r	Svojstvena vrijednost	λ_{trace} test	λ_{trace} test*	P-vrijednost	P-vrijednost*
2	0	0,088	22,794	21,795	0,103	0,130
1	1	0,046	7,752	7,518	0,287	0,287

Izvor: autorov izračun

Napomena: * označuje vrijednosti korigirane Bartlett korekcijom (Johansen, 2002) za male uzorke

pokazuju da je UVAR model prikladno oblikovan jer ne treba odbaciti nul hipoteze o nepostojanju autokorelacije i nenormalnosti reziduala. Za razliku od prethodnog modela, u ovome modelu multivarijantni test autoregresivne uvjetne heteroskedastičnosti (ARCH) jasno pokazuje da nul hipotezu o nepostojanju ARCH utjecaja ne treba odbaciti.

Tablica 4. Testovi pogrešne specifikacije neograničenoga VAR modela (DLN-CROBEX, DLNCPI)

Multivarijantni testovi:		
Test autokorelacije		
LM(1)		Hi-kvadrat (4) = 6,134 [0,189]
Test normalnosti		Hi-kvadrat 4) = 4,084 [0,395]
Test autoregresivne uvjetne heteroskedastičnosti (ARCH)		
LM(1)		Hi-kvadrat (9) = 13,427 [0,144]
Univarijantni testovi:		
	DDLNCROBEX	DDLNCPI
Asimetrija – treći moment	-0,011	0,352
Zaobljenost – četvrti moment	3,112	3,060
ARCH	6,427 [0,011]	1.212 [0,271]
Jarque-Bera	0,558 [0,756]	3.598 [0,165]
R ²	0,611	0,723

Izvor: autorov izračun

Napomena: P-vrijednosti su u uglatim zagradama

Kako je istaknuto u poglavlju o ekonometrijskoj metodologiji, Grangerov test uzročnosti temeljen na *bootstrap* metodi moguće je provesti neovisno o nestacionarnosti promatranih varijabli. Rezultati ovoga testa prikazani su u Tablici 5.

Tablica 5. Testovi Grangerove uzročnosti na nestacionarnim varijablama

Test Grangerove uzročnosti temeljen na <i>bootstrap</i> metodi (VAR – LNCROBEX, LNCPI); LNCROBEX → LNCPI	[0,27843]
Test Grangerove uzročnosti temeljen na <i>bootstrap</i> metodi (VAR – LNCROBEX, LNCPI); LNCPI → LNCROBEX	[0,14743]

Izvor: autorov izračun

Napomena: P-vrijednosti su u uglatim zagradama

Iz Tablice 5. jasno je vidljivo da u Grangerovu smislu niti varijabla LNCROBEX uzrokuje LNCPI niti varijabla LNCPI uzrokuje varijablu LNCROBEX. U slučaju da su varijable stacionarne, moguće je primijeniti i standardni test Grangerove uzročnosti i test Grangerove uzročnosti temeljen na *bootstrap* metodi. S obzirom na to da je oblikovan UVAR model koji sadrži diferencirane varijable, na temelju ovog modela provedeni su spomenuti testovi, a njihovi rezultati prikazani su u Tablici 6.

Tablica 6. Testovi Grangerove uzročnosti na stacionarnim varijablama

Standardni test Grangerove uzročnosti (VAR – DLNCROBEX, DLNCPI); DLNCROBEX $\rightarrow$ DLNCPI	F(1,147) = 2,562611 [0,11156]
Standardni test Grangerove uzročnosti (VAR – DLNCROBEX, DLNCPI); DLNCPI $\rightarrow$ DLNCROBEX	F(1,147) = 0,221832 [0,63835]
Test Grangerove uzročnosti temeljen na <i>bootstrap</i> metodi (VAR – DLNCROBEX, DLNCPI); DLNCROBEX $\rightarrow$ DLNCPI	[0,11400]
Test Grangerove uzročnosti temeljen na <i>bootstrap</i> metodi (VAR – DLNCROBEX, DLNCPI); DLNCPI $\rightarrow$ DLNCROBEX	[0,64490]

Izvor: autorov izračun

Napomena: P-vrijednosti su u uglatim zagradama

Kao i rezultati testova Grangerove uzročnosti na nestacionarnim varijablama, rezultati testova na stacionarnim varijablama također pokazuju da ne postoji uzročnost u Grangerovu smislu niti s varijable DLNCROBEX na DLNCPI niti obrnuto. Dakle, u ovome slučaju, Grangerov test je robustan u odnosu na postojanje jediničnog korijena u promatranim varijablama.

5. ZAKLJUČAK

Cilj ovoga rada bio je istražiti utjecaj inflacije na cijenu dionica u Republici Hrvatskoj. Teorijski promatrano, ovaj utjecaj može biti pozitivan ili negativan. Stoga je u radu provedena ekonometrijska analiza, preciznije analiza vremenskih nizova promatranih varijabli. Kao varijable kojima je mjerena inflacija i cijene dionica korišten je indeks potrošačkih cijena i dionički indeks CROBEX, slijedom. U svrhu istraživanja spomenutoga utjecaja izgrađen je empirijski model, preciznije bivarijantni neograničeni vektorski autoregresivni model. Nakon što je izgrađen model pokazao prikladna ekonometrijska svojstva, bio je temelj daljnje analize. Drugim riječima, na temelju ovoga modela testirana je kointegracija Johansenovom metodologijom i provedena su dva testa Grangerove uzročnosti – standardni test i test temeljen na *bootstrap* metodi. Testiranjem je pokazano da se kointegracija ne može prihvatiti pa nema dugoročne povezanosti između promatranih varijabli. Isto tako, testovi Grangerove uzročnosti pokazuju da nul hipoteza o nepostojanju Grangerove uzročnosti ne može biti odbačena na uobičajenim razinama statističke značajnosti.

Rezultati istraživanja pokazuju, dakle, da utjecaj inflacije na cijene dionica u Republici Hrvatskoj nije ekonometrijski opaziv. U vrijeme pisanja ovoga rada podaci o indeksu CROBEX bili su javno dostupni tek od siječnja 2010. godine.

Ovo, relativno kratko razdoblje, jedan je od mogućih uzroka konačnih rezultata ovoga istraživanja. Sljedeći je mogući uzrok i dominantan udio poslovnih banaka u relativno malom financijskom sustavu u zemlji. Stoga će buduća istraživanja zasigurno pokušati pokazati hoće li proširenje razdoblja istraživanja i razvoj financijskog tržišta, ponajprije u smislu rasta broja i promjene strukture sudionika, pokazati drugačije rezultate.

REFERENCE

1. Arnerić, J. i Vladović, L. (2021) Makroekonomske determinante dioničkih cijena na primjeru Hrvatske, *Ekonomski pregled*, Vol. 72, No. 2, str. 199-223.
2. Barbić, T. i Čondić-Jurkić, I. (2011) Relationship Between Macroeconomic Fundamentals and Stock Market, *Ekonomski pregled*, Vol. 63 No. 3-4, str. 113-133.
3. Bruno, G. S. F. (2005) Approximating the bias of the LSDV estimator for dynamic unbalanced panel data models, *Economics Letters* Vol. 87, No. 3, 361-366.
4. Efron, B. (1979) Bootstrap Methods: Another Look at the Jackknife, *Annals of Statistics* 7, str. 1-26.
5. Fama, E. F. (1981) Stock returns, real activity, inflation, and money", *American Economic Review*, Vol. 71 No. 4, str. 545-565.
6. Feldstein, M. (1980) Inflation and the Stock Market, *American Economic Review*, Vol. 70, No. 5, str. 839-847.
7. Fisher, I. (1896) Appreciation and Interest, *Publications of the American Economic Association*, Vol. 11, No. 4, str. 1-98.
8. Geske, R. i Roll, R. (1983) The Fiscal and Monetary Linkage Between Stock Returns and Inflation, *The Journal of Finance*, Vol. 38, No. 1, str. 1-33.
9. Granger, C. W. J. (1969) Investigating causal relations by econometric models and cross-spectral methods, *Econometrica*, Vol. 37 No. 3, str. 424-438.
10. Hendry, D. i Juselius, K. (2001) Explaining Cointegration Analysis: Part II., *The Energy Journal*, Vol. 22, No. 1, str. 75-120.
11. Hrvatska narodna banka, <https://www.hnb.hr/> [9. veljače 2024.]
12. Hsing, Y. (2011) Macroeconomic variables and the stock market: The case of Croatia, *Economic research - Ekonomska istraživanja*, Vol. 24, No. 4, str. 41-50.
13. Johansen, S. (1988) Statistical Analysis of Cointegration Vectors, *Journal of Economic Dynamics and Control*, Vol. 12, No. 2-3, str. 231-254.
14. Johansen, S. (1991) Estimation and Hypothesis Testing of Cointegration Vectors in Gaussian Vector Autoregressive Models, *Econometrica*, Vol. 59, No. 6, str. 1551-1580.
15. Johansen, S. (1992) Determination of Cointegration Rank in the Presence of a Linear Trend, *Oxford Bulletin of Economics and Statistics*, Vol. 54, No. 3, str. 383-397.
16. Johansen, S. (1994) The role of the constant and linear terms in cointegration analysis of nonstationary variables, *Econometric Reviews*, Vol. 13, No. 2, str. 205-229.

17. Johansen, S. (1995) *Likelihood-Based Inference in Cointegrated Vector Autoregressive Models*. New York: Oxford University Press.
18. Johansen, S. (2002) A small sample correction of the test for cointegrating rank in the vector autoregressive model, *Econometrica*, Vol. 70, No. 5, str. 1929–1961.
19. Johansen, S. i Juselius, K. (1990) Maximum Likelihood Estimation and Inference on Cointegration – with Applications to the Demand for Money, *Oxford Bulletin of Economics and Statistics*, Vol. 52, No. 2, str. 169–210.
20. Johansen, S. i Juselius, K. (1992) Testing Structural Hypotheses in a Multivariate Cointegration Analysis of the PPP and the UIP for UK, *Journal of Econometrics*, Vol. 53, No. 1-3, str. 211-244.
21. Johansen, S. i Juselius, K. (1994) Identification of the Long-Run and the Short-Run Structure. An Application of the ISLM Model, *Journal of Econometrics*, Vol. 63, No. 1, str. 7-36.
22. Juselius, K. (2006). *The Cointegrated VAR Model: Methodology and Applications*, Advanced Texts in Econometrics. Oxford: Oxford University Press.
23. Modigliani, F. i Cohn, R. A. (1979) Inflation, rational valuation, and the market, *Financial Analysts Journal*, Vol. 35, No. 2, str. 24-44.
24. Nelson, D. B. (1991) Conditional heteroscedasticity in asset returns: a new approach, *Econometrica*, Vol. 59, No. 2, str. 347–370.
25. Phillips, P. C. B. i Perron, P. (1988) Testing for a unit root in time series regressions, *Biometrika*, Vol. 75, str. 335–346.
26. Pindyck, S. R. (1984) Risk, Inflation, and the Stock Market, *American Economic Review*, Vol. 74, No. 3, str. 335- 351.
27. Rahbek, A., Hansen, E. i Dennis, G. J. (2002). ARCH innovations and their impact on cointegration rank testing, *Centre for Analytical Finance*, Working paper no. 22, University of Copenhagen.
28. Rose, A. P. i Marquis, H. M. (2008) *Money and Capital Markets*, New York: McGraw-Hill/Irwin.
29. Schmidt, P. i Phillips, P. (1992) LM Test for a Unit Root in the Presence of Deterministic Trends, *Oxford Bulletin of Economics and Statistics*, Vol. 54, str. 257-287.
30. Sims, C.A., Stock, J. H. i Watson, M. W. (1990) Inference in Linear Time Series Models with Some Unit Roots, *Econometrica*, Vol. 58, No. 1, str. 113-144.
31. Zagrebačka burza, <https://zse.hr/> [9. veljače 2024.]

THE EFFECT OF INFLATION ON STOCK PRICES IN THE REPUBLIC OF CROATIA

Associate Professor Dražen Koški, PhD

J. J. Strossmayer University in Osijek, Faculty of Economics in Osijek
e-mail: dkoski@efos.hr

ABSTRACT

The aim of this paper was to investigate the effect of inflation on stock prices in the Republic of Croatia. For this purpose, a time series analysis covering the period from January 2010 to October 2023 was conducted. Inflation was measured by the consumer price index (CPI) and stock prices by the stock price index of the Zagreb Stock Exchange – CROBEX. The analysis was carried out in two ways. First, a cointegration test between the consumer price index and CROBEX was performed to check for a possible long-term relationship between these variables. The Johansen methodology was used to test for cointegration. Second, it was tested whether one variable causes the other in the Granger sense. The standard Granger causality test and the Granger causality test based on the bootstrap method were applied. The research results show that there is no long-term relationship between inflation and stock prices. Additionally, neither variable causes the other in the Granger sense.

Keywords: inflation, CROBEX, cointegration, Granger causality, bootstrap method

JEL classification: C32, E31, G10

PREGLED IZRAVNIH STRANIH ULAGANJA U TURIZMU NA GLOBALNOJ RAZINI

prof. dr. sc. Elvis Mujačević

Sveučilište u Rijeci, Fakultet za menadžment u turizmu i ugostiteljstvu
e-mail: elvism@fthm.hr

SAŽETAK

Inozemnim stranim ulaganjima daje se važnost u stvaranju radnih mjesta poticanjem zapošljavanja u raznim sektorima povezanim s turizmom (ugostiteljstvo, promet, trgovina i dr.). Povećane stope zaposlenosti, pak, dovode do poboljšanja životnog standarda lokalnih zajednica. S tog aspekta promatrano, nameće se potreba istraživanja tokova izravnih stranih ulaganja po pojedinim globalnim regijama te analiziranje utjecaja izravnih stranih ulaganja na otvaranje novih radnih mjesta. Pregled izravnih stranih ulaganja na globalnoj razini po pojedinim regijama svijeta (AzijaPacifik, Europa, Sjeverna Amerika, Latinska Amerika i Karibi, Bliski istok i Afrika) u razdoblju od 2013. do 2021. godine ukazuje na dinamiku izravnih ulaganja po pojedinim godinama, pri čemu je najveći broj projekata i kapitalnih ulaganja gotovo u svim regijama realiziran neposredno prije pandemije bolesti COVID-19. Uz korištenje deskriptivne statistike, došlo se do zaključka o značajnoj pozitivnoj i jakoj vezi izravnih stranih ulaganja i novootvorenih radnih mjesta u svim regijama svijeta.

Ključne riječi: turizam, otvaranje novih radnih mjesta, izravna strana ulaganja

JEL klasifikacija: F01, F21, L83, 05, Z3, Z32

1. UVOD

Svjetska banka (engl. *The World Bank*) (2022) izvještava o turističkom sektoru kao najvećem uslužnom sektoru prije pandemije bolesti COVID-19, koji osigurava jedno od deset radnih mjesta širom svijeta, gotovo sedam % ukupne međunarodne trgovine i 25 % svjetskog izvoza usluga, i time je ujedno bio ključni generator deviza. Nakon značajnog smanjenja broj međunarodnih turističkih dolazaka u 2020. godini, zbog poduzetih mjera sprječavanja širenja korona-vi-

rusa na globalnoj razini, turistički pokazatelji (broj turističkih dolazaka i noćenja, prihodi od turizma) ukazuju na otpornost i brz oporavak turizma. Prema podacima UNWTO-a (2024), prihodi od međunarodnog turizma u 2023. godini iznosili su 1,4 bilijuna USD te su dosegli oko 93 % ostvarenih prihoda iz 2019. godine, dok su ukupni izvozni prihodi od turizma u 2023. godini realizirani u iznosu od 1,6 bilijuna USD dosežući 95 % izvoznih prihoda od turizma iz 2019. godine. Ekonomski doprinos turizmu, mjerjen izravnim bruto domaćim proizvodom (BDP), ukazuje na 3,3 bilijuna USD u 2023. godini ili 3 % globalnog BDP-a. Oporavak izravnog BDP-a potaknut je snažnim rastom domaćeg i međunarodnog turizma. Turistički rezultati usko su povezani s investicijama u turističku infrastrukturu. Izravna strana ulaganja (engl. *Foreign direct investment*, FDI) imaju važnu ulogu u mnogim zemljama, posebice u zemljama u razvoju. Galičić i Maškarin (2016) ukazuju na to da se učinci FDI-a u turističkoj industriji prelijevaju na domaće gospodarstvo putem veza koje se uspostavljaju s lokalnim dobavljačima, konkurentima i drugim dionicima u turizmu. Kapital stranih ulagača pomaže u stvaranju radnih mjesta, potičući zapošljavanje u raznim sektorima povezanim s turizmom (ugostiteljstvo, promet, trgovina i dr.). Povećane stope zaposlenosti, pak, dovode do poboljšanja životnog standarda lokalnih zajednica. Štoviše, FDI olakšava razvoj infrastrukture povezane s turizmom, uključujući hotele, odmarališta, prometne mreže i rekreacijske sadržaje. Ova ulaganja povećavaju ukupnu konkurentnost destinacije, čineći je privlačnijom međunarodnim turistima i stvarajući pozitivan ciklus gospodarskog rasta.

Značaj koji FDI ima u turizmu ukazuje na potrebu pregleda njegovih tokova po pojedinim globalnim regijama te analiziranja utjecaja FDI-a na otvaranje novih radnih mjesta. Cilj rad jest dati pregled trendova FDI-a u turizmu na globalnoj razini te istražiti odnos FDI-a i novih radnih mjesta u turizmu.

2. PREGLED LITERATURE

FDI se definira kao ulaganja radi stjecanja trajnog interesa u poduzećima koja djeluju izvan gospodarstva ulagača (IMF, 1993; WTO, 1996). U literaturi je zastupljen znatan broj studija koje obuhvaćaju FDI s različitih aspekata (Dunning i Lundan, 2008; Moosa 2009; Cambazoglu i Simy Karaalp, 2014; Tang, 2017). Unatoč tome, postoji još uvijek prostora za daljnja istraživanja, posebice u različitim sektorima. Znatian dio literature odnosi se na determinante FDI-a i motive koji pokreću multinacionalne kompanije da prošire svoje poslovanje izvan nacionalnih granica (Chakrabarti, 2001; Coskun, 2001; Asiedu, 2002;

Wei, 2005; Dunning i Lundan, 2008; Rodríguez i Pallas, 2008; Wijeweera i Mo-
unter, 2008, Moosa, 2009; Zheng, 2009; Mah i Yoon, 2010; Dhingra i Sidhu,
2011). Autori su se usmjerili i na međunacionalne studije o determinantama
FDI-a u ekonomijama Europske unije (Bevan i Estrin, 2004; Bellak *et al.*, 2009;
Casi i Resmini, 2010; Igošina, 2015; Janicki i Wunnava, 2004; Leonardo *et al.*,
2018; Oezkan-Guenay, 2011; Villaverde i Maza, 2015; Stack *et al.*, 2017; Su *et al.*, 2018; Villaverde i Maza, 2015; Tang, 2017).

U sektoru turizma, unatoč rastu broja međunarodnih turističkih putovanja na globalnoj razini (porast broja turističkih dolazaka, rast prihoda od turizma) te rastu FDI-a u turizmu posljednjih dvaju desetljeća, istraživanja FDI-a u sektoru turizma vrlo su malo zastupljena. UNWTO (2001) promatra FDI u turizmu kao novo i malo istraženo područje istraživanja. Istraživanja se uglavnom odnose na ispitivanje uzročnih veza turizma, FDI-a i ekonomskog rasta (Khoshnevis *et al.*, 2015; Sokhanvar, 2022) te rasta turizma vođenog stranim ulaganjima (Bezić, Nikšić Radić i Kandžija, 2010; Bezić i Nikšić Radić, 2017). Odnos između dviju varijabli, turizma i FDI-a nije, međutim, jednosmjernan. Othman, Salleh i Sarmidi (2012) ukazuju na postojanje višesmjerne povezanosti između razvoja turističke industrije, gospodarskog rasta i FDI-a.

Hipoteza o pozitivnom utjecaju turizma na zapošljavanje temelji se na ideji da turizam stvara izravna, neizravna i inducirana zapošljavanja u regionalnim i nacionalnim gospodarstvima (Zhao *et al.*, 2023). Istraživanja ukazuju na pozitivan utjecaj FDI-a na rast zaposlenosti (Karlsson *et al.*, 2009), no prisutna su i istraživanja koja ukazuju na rast produktivnosti radnika, ali ne i na rast zaposlenosti (Siddharthan i Narayanan, 2020), kao i istraživanja koja dolaze do saznanja o negativnim učincima FDI-a na zaposlenost, odnosno o gubitku radnih mjesta pod utjecajem FDI-a (Mamoon i Rahman, 2016). U području turizma, međutim, literatura (Zhao *et al.*, 2023) pokazuje da međunarodni turizam potiče zapošljavanje u turističkim destinacijama. Ipak, postoji još otvorenih pitanja koja iziskuju daljnja istraživanja, primjerice, kretanje FDI-a u turizmu na globalnoj razini, kao i utjecaj FDI-a u turizmu na otvaranje novih radnih mjesta.

3. PREGLED IZRAVNIH STRANIH ULAGANJA PO REGIJAMA SVIJETA

Turizam je u mnogim zemljama svijeta pojava koja potiče rast gospodarskih djelatnosti izravno ili neizravno povezanih s turizmom generirajući nova radna mjesta, rast bruto domaćeg proizvoda, izravnih stranih ulaganja i dr. (Bezić,

Nikšić Radić i Kandžija, 2010; Bezić i Nikšić Radić, 2017; Khoshnevis *et al.*, 2015; Sokhanvar, 2022; Zhao *et al.*, 2023). Privlačnost turizma za strana ulaganja prati se putem trendova FDI-a u pojedinim regijama svijeta: Azija-Pacifik, Europa, Sjeverna Amerika, Latinska Amerika i Karibi, Bliski istok i Afrika.

3.1. FDI PROJEKTI U AZIJI I NA PACIFIKU 2013. – 2021. GODINE


Između 2013. i 2021. godine najavljeno je ukupno 996 FDI projekata u azijsko-pacifičkoj regiji. To je rezultiralo kapitalnim ulaganjima u vrijednosti od 103,4 milijarde USD i otvaranjem više od 187.740 radnih mjesta. Što se tiče projekata, izravna strana ulaganja u turizam u azijsko-pacifičkoj regiji dosegla su vrhunac 2018. godine, kada su najavljena 194 ulaganja vrijedna 28,6 milijardi USD i otvoreno 47.010 radnih mjesta. Iznos kapitalnih ulaganja u regiji pao je s 28,6 milijardi USD u 2018. na samo 1,6 milijardi USD u 2021. godini, dok je broj otvorenih radnih mjesta smanjen s oko 47.400 na 3.300 (Tablica 1.). Pearsonov koeficijent korelacije ($r = 0,984$) pokazuje značajnu i pozitivnu povezanost kapitalnih ulaganja i otvaranja radnih mjesta.

Tablica 1. Izravna strana ulaganja u turizam u Aziju i Pacifik 2013. – 2021. godine

Godina	Kapitalna ulaganja		Ukupan broj projekata		Otvorena radna mjesta	
	Vrijednost, mlrd. USD	Verižni indeks	Apsolutni broj	Verižni indeks	Apsolutni broj	Verižni indeks
2013.	9,6	-	122	-	17.451	-
2014.	3,4	35,4	76	62,3	7.642	43,8
2015.	8,0	235,3	86	113,2	15.102	197,6
2016.	10,3	128,8	99	115,1	20.605	136,4
2017.	6,3	61,1	84	84,8	18.250	88,6
2018.	28,6	454,0	193	229,8	47.010	157,5
2019.	24,3	85,0	167	86,5	37.009	78,7
2020.	5,0	20,6	53	31,7	9.030	24,4
2021.	1,6	32,0	32	60,4	3.029	33,5
Ukupno	103,4		996		187.740	

Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2019), *Tourism Investment 2018*. Dostupno na: <https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-09/fDi-Tourism-Investment-2018.pdf> [9. listopada 2023.]; fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

Grafikon 1. Otvorena i procijenjena radna mjesta u regiji Azije i Pacifika, 2013. - 2021. godine



Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2019), *Tourism Investment 2018*. Dostupno na: <https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-09/fDi-Tourism-Investment-2018.pdf> [9. listopada 2023.]; fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

Kina je privukla najveći udio stranih ulaganja u turizam u azijsko-pacifičkoj regiji između 2013. i 2021. godine, s 208 ekvivalentnih ulaganja ili tržišnim udjelom od 20,97 %. Zabilježen je, također, rast projekata od 26 % između 2018. i 2019. godine, ali je broj projekata smanjen na četiri u 2021., odnosno za 86 % u odnosu na 2019. godinu. Kinu slijede Indija (119), Singapur (89) i Japan (89) u broju projekata u sektoru turizma između 2013. i 2021. godine. Indija je druga u azijsko-pacifičkoj regiji po ukupnim ulaganjima od 2013. do 2021. godine, s 12 % tržišnog udjela, ali je privukla najmanji broj turističkih projekata, sa samo dva investicijska projekta u 2021. godini. To je pad ulaganja od 88 % od 2019. godine, kada je Indija dosegla najvišu razinu ulaganja (fDi Intelligence, 2019; fDi Intelligence, 2020; fDi Intelligence, 2023).

Tablica 2. Vodeće zemlje u Aziji i na Pacifiku po broju projekata, 2013. – 2021. godine

Zemlja	Broj projekata	Udio turističkih FDI projekata, u %
Kina	208	21,0
Indija	119	12,0
Singapur	89	9,0
Japan	89	9,0
Australija	88	9,0

Zemlja	Broj projekata	Udio turističkih FDI projekata, u %
Vijetnam	60	6,1
Tajland	51	5,1
Indonezija	44	4,4
Hong Kong	39	3,9
Južna Koreja	14	1,4
Ostale zemlje	191	19,2

Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

Treća zemlja s najvećim brojem projekata od 2013. do 2021. godine jest Singapur s 89 investicija i tržišnim udjelom od 8,97 %. U 2021. godini broj projekata u Singapuru povećan je na ukupno šest projekata s ukupnim ulaganjem od 25 milijuna USD i 168 otvorenih radnih mjesta, što je dvostruko više od ulaganja u turizam 2020. godine. Time je grad-država dobio najviše turističkih ulaganja u cijeloj Azijsko-pacifičkoj regiji. No, u odnosu na 2019. godinu, ulaganja su manja za 50 %.

Japan je, također privukao 89 projekata u razdoblju od 2013. do 2021. godine, isti tržišni udio kao Singapur i Australija s 88 projekata. U 2018. godini u Japanu je najavljeno 28 investicijskih projekata, što je ujedno i najveći broj ostvarenih investicijskih projekata, no, između 2018. i 2021. godine broj projekata u značajnom je opadanju te je u 2021. godini ostvareno samo jedno ulaganje. Iznos ulaganja i broj otvorenih radnih mjesta u Japanu, također, doseže vrhunac u 2018. godini (fDi Intelligence, 2019; fDi Intelligence, 2020; fDi Intelligence, 2023).

3.2. FDI PROJEKTI U EUROPI 2013. – 2021. GODINE

Između 2013. i 2021. godine u Europi je zabilježeno 1.317 turističkih FDI projekata kojima je realizirano 67,7 milijardi USD ulaganja u turizam te otvaranja više od 142.423 radnih mjesta (Tablica 3.). Pearsonov koeficijent ($r = 0,960$) potvrđuje značajnu i pozitivnu povezanost kapitalnih ulaganja i otvorenih radnih mjesta. U 2019. godini ulaganja u turizam u Europi dosegla su vrhunac, s 293 projekta, 11,4 milijarde USD kapitalnih ulaganja i gotovo 26.311 otvorenih radnih mjesta. U Velikoj Britaniji realizirana je većina europskih turističkih FDI projekata s tržišnim udjelom od 19,6 %, a ujedno je sudjelovala i s najvećim udjelom u otvaranju radnih mjesta. Veliku Britaniju slijedi Španjolska sa 179 projekata i tržišnim udjelom od 12 % te Njemačka sa 171 projektom i tržišnim udjelom od 11,74 %. Dvije zemlje zajedno su privukle 350 projekata i imale tržišni udio od 23,74 %.


Tablica 3. Izravna strana ulaganja u turizam u Europi 2013. – 2021. godine

Godina	Kapitalna ulaganja		Ukupno projekti		Otvorena radna mjesta	
	Vrijednost, u mlrd. USD	Verižni indeks	Apsolutni broj	Verižni indeks	Apsolutni broj	Verižni indeks
2103.	4,0	-	102	-	12.941	-
2014.	1,9	47,5	92	90,2	5.892	45,5
2015.	5,3	278,9	106	115,2	13.311	225,9
2016.	3,7	69,8	108	101,9	10.441	78,4
2017.	7,1	191,9	138	127,8	16.140	154,5
2018.	25,5	359,2	215	155,8	35.442	219,6
2019.	11,4	44,7	293	136,3	26.311	74,2
2020.	5,1	44,7	135	46,1	11.441	43,4
2021.	3,7	75,5	128	94,8	10.504	91,2
Ukupno	67,7		1317		142.423	

Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2019), *Tourism Investment 2018*. Dostupno: <https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-09/fDi-Tourism-Investment-2018.pdf> [9. listopada 2023.]; fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

I kapitalna ulaganja i broj radnih mjesta potaknuti izravnim stranim ulaganjima u turizmu u Europi dosegli su 2018. godine najvišu razinu u povijesti, s uloženih 25,5 milijardi USD i 35.442 otvorena radna mjesta. Između 2018. i 2021. godine kapitalna ulaganja u Europi smanjena su za 21,7 milijardi USD, dok je broj novootvorenih radnih mjesta smanjen za 70 %.

Grafikon 2. Otvorena i procijenjena radna mjesta u regiji Europe



Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2019), *Tourism Investment 2018*. Dostupno na: <https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-09/fDi-Tourism-Investment-2018.pdf> [9. listopada 2023.]; fDi Intelli-

gence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

Španjolska je bila vodeća destinacija s 21,2 milijarde dolara kapitalnih ulaganja i 22.900 radnih mjesta stvorenih između 2017. i 2021. Između 2013. i 2021. Turska je bila glavni cilj u Europi u nastajanju u smislu broja projekata (Tablica 4). Privukla je 55 projekata u turizam ukupne vrijednosti 332,5 milijuna dolara te otvorilo 2.200 radnih mjesta (fDi Intelligence, 2019; fDi Intelligence, 2020; fDi Intelligence, 2023).

Tablica 4. Vodeće zemlje u Europi po broju projekata 2013. – 2021. godine

Država	Broj projekata	Udio turističkih FDI projekata, u %
Velika Britanija	285	19,6
Španjolska	179	12,0
Njemačka	171	11,7
Francuska	140	13,9
Portugal	78	9,6
Italija	62	4,3
Nizozemska	57	3,9
Turska	55	3,8
Irska	41	2,8
Poljska	25	1,7
Rusija	19	1,3
Ostale zemlje	344	23,6

Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

3.3. FDI PROJEKTI U SJEVERNOJ AMERICI 2013. – 2021. GODINE

Sjeverna Amerika privukla je 284 projekta izravnih stranih ulaganja u turizmu između 2013. i 2021. godine, uloživši gotovo 21,5 milijardi dolara i otvorivši više od 44.111 radnih mjesta (Tablica 5.). I ulaganja i broj radnih mjesta kreiranih izravnim stranim ulaganjima u turizmu u Sjevernoj Americi dosegli su vrhunac 2019. godine s 3,5 milijardi USD ulaganja i otvorenih 6.420 radnih mjesta. U 2021. godini zabilježeno je 28 turističkih projekata — povećanje od 4 % u usporedbi s 2020. godinom. Ti su projekti generirali 776 milijuna USD (smanjenje od 37 % u odnosu na 2020. godinu) i stvorili približno 2.400 radnih mjesta (31 % manje nego 2020. godine). Izravna strana ulaganja u turizam u Sjevernoj Americi porasla su s dvije milijarde USD 2017. godine na više od 3,4 milijarde USD u 2019. godini, prije nego što su smanjeni na 1,2 milijarde USD

2020. godine. U 2021. godini ulaganja u regiji smanjena su na 776 milijuna USD (fDi Intelligence, 2019; fDi Intelligence, 2020; fDi Intelligence, 2023). I u ovoj regiji Pearsonov koeficijent korelacije ($r = 0,897$) potvrđuje značajnu i jaku pozitivnu međusobnu povezanost izravnih stranih ulaganja i otvaranja novih radnih mjesta.

Tablica 5. FDI iz turizma u Sjevernoj Americi 2013. – 2021. godine

Godina	Kapitalna ulaganja		Ukupno projekti		Otvorena radna mjesta	
	Vrijednost, u mlrd. USD	Verižni indeks	Apsolutni broj	Verižni indeks	Apsolutni broj	Verižni indeks
2013.	2,5	-	22	-	6.576	-
2014.	2,5	100	17	77,3	6.140	93,4
2015.	4,6	184	34	200,0	7.190	117,1
2016.	1,2	26,1	25	73,5	2.151	29,9
2017.	2,9	241,7	32	128,0	5.412	251,6
2018.	2,4	82,8	44	137,5	4.600	85,0
2019.	3,4	141,7	53	120,5	6.420	139,6
2020.	1,2	35,3	28	52,8	3.410	53,1
2021.	0,8	66,7	29	103,6	2.212	64,9
Ukupno	21,5		284		44.111	

Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2019), *Tourism Investment 2018*. Dostupno na: <https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-09/fDi-Tourism-Investment-2018.pdf> [9. listopada 2023.]; fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

Grafikon 3. Otvorena i procijenjena radna mjesta u regiji Sjeverne Amerike, 2013. - 2021. godine



Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2019), *Tourism Investment 2018*. Dostupno na: <https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-09/fDi-Tourism-Investment-2018.pdf>

s3fs-public/2020-09/fDi-Tourism-Investment-2018.pdf [9. listopada 2023.]; fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

Vodeća američka država po projektima izravnih stranih ulaganja u turizmu između 2013. i 2021. godine bila je New York (62), a slijede je Florida (54) i Kalifornija (39). Ove tri države čine gotovo polovicu svih projekata izravnih stranih ulaganja u turizmu u regiji.

Kalifornija i Florida imale su zajedno 93 projekta i činile 34,96 % tržišnog udjela turističkih FDI projekata i 33 % turističkih ulaganja u Sjevernoj Americi između 2017. i 2021. godine. Tijekom tog razdoblja, Florida je osigurala veći broj turističkih projekata, kapitalnih ulaganja i radnih mjesta u odnosu na Kaliforniju (fDi Intelligence, 2019; fDi Intelligence, 2020; fDi Intelligence, 2023).

Tablica 6. Vodeće zemlje u Sjevernoj Americi prema broju projekata 2013. – 2021. godine

Zemlja	Broj projekata	Udio turističkih FDI projekata u Sjevernoj Americi 2017. - 2021. godine, u %
New York	62	23,3
Florida	54	20,3
Kalifornija	39	14,7
Ontario	19	7,1
Nevada	6	2,3
Britanska Kolumbija	5	1,9
Alberta	4	1,5
New Jersey	4	1,5
Quebec	4	1,5
Illinois	4	1,5
Colorado	3	1,1
Ostale zemlje	62	23,3

Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

3.4. FDI U LATINSKOJ AMERICI I NA KARIBIMA 2013. - 2021. GODINE

Latinska Amerika i Karibi privukli su 448 projekata izravnih stranih ulaganja u turistički sektor između 2013. i 2021. godine (Tablica 7.). Tijekom ovog osmo-godišnjeg razdoblja otvoreno je više od 158.885 novih radnih mjesta, a u regiju

je uloženi kapital u vrijednosti od 36,6 milijardi USD. Pearsonov koeficijent korelacije ($r = 0,921$) pokazuje značajnu pozitivnu i jaku povezanost izravnih stranih ulaganja u turizam i broja novootvorenih radnih mjesta.

Meksiko, Brazil i Kolumbija (tri vodeće destinacije u regiji za izravna strana ulaganja u turizmu između 2013. i 2021. godine) činili su više od polovice svih izravnih stranih ulaganja u turizmu regije. Meksiko je najprivlačnija zemlja za strane turističke investicije u razdoblju od 2103. do 2107. godine s 28,8 % turističkih projekata u Latinskoj Americi, 36,6 % otvorenih radnih mjesta u turizmu i gotovo 33 % turističkih ulaganja.


Godina 2017. bila je najbolja godina za ulaganje u turizam u Meksiku. Uloženo je više od 1,3 milijarde USD, najavljeno je 20 projekata i otvoreno više od 10.600 radnih mjesta.

Tablica 7. Izravna strana ulaganja u turizam u Latinsku Ameriku i Karibe, 2013. – 2021. godine

Godina	Kapitalna ulaganja		Ukupno projekti		Otvorena radna mjesta	
	Vrijednost, u mlrd. USD	Verižni indeks	Apsolutni broj	Verižni indeks	Apsolutni broj	Verižni indeks
2103.	3,5	-	50	-	22.929	-
2014.	1,0	28,6	19	38,0	6.673	29,1
2015.	2,0	200,0	19	100,0	14.354	215,1
2016.	2,4	120,0	32	168,4	15.857	110,5
2017.	3,7	154,2	55	171,9	15.000	94,6
2018.	8,3	224,3	133	241,8	34.750	231,7
2019.	11,3	136,1	95	71,4	35.680	102,7
2020.	3,6	31,9	29	30,5	10.800	30,3
2021.	0,8	22,2	16	55,2	2.812	26,0
Ukupno	36,6		448		158.885	

Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2019), *Tourism Investment 2018*. Dostupno na: <https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-09/fDi-Tourism-Investment-2018.pdf> [9. listopada 2023.]; fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

Grafikon 4. Otvorena i procijenjena radna mjesta u regiji Latinske Amerike i Kariba, 2013. - 2021. godine



Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2019), *Tourism Investment 2018*. Dostupno na: <https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-09/fDi-Tourism-Investment-2018.pdf> [9. listopada 2023.]; fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

U 2021. godini investicije u Latinskoj Americi i na Karibima smanjile su se za 78 % u odnosu na 2020. godinu, s 3,6 milijardi USD na 800 milijuna USD. Tijekom tog razdoblja, otvaranje novih radnih mjesta u regiji, također, je značajno smanjeno, s oko 10.500 u 2020. na 3.200 u 2021. godini.

Meksiko je bio vodeće ciljno tržište u regiji Latinske Amerike i Kariba između 2017. i 2021. godine, sa sudjelovanjem od 33 % (108) u ukupnim izravnim stranim ulaganjima u turizmu regije. S tržišnim udjelom od 33 % (9,3 milijarde USD), Meksiko je također bio vodeća zemlja u pogledu kapitalnih ulaganja te je otvoren najveći broj novih radnih mjesta u regiji (33.800).

Kolumbija i Peru zauzeli su drugo i treće mjesto u izravnim stranim ulaganjima u turizam s 40, odnosno 30 projekata između 2017. i 2021. godine, pri čemu je Kolumbija zauzela 12 % tržišnog udjela, a Peru 9,1 %. Kolumbija je, također, bila na drugom mjestu po kapitalnim ulaganjima s 5,5 milijardi USD, što predstavlja 20 % regionalnih ukupnih ulaganja u petogodišnjem razdoblju (fDi Intelligence, 2019; fDi Intelligence, 2020; fDi Intelligence, 2023).

Tablica 8. Vodeće zemlje u Latinskoj Americi i Karibima po broju projekata 2013. – 2021.

Zemlja	Broj projekata	Udio turističkih FDI projekata u Latinskoj Americi i Karibima 2013. – 2021. godine, u %
Meksiko	161	31,5
Kolumbija	59	10,3
Brazil	53	10,4
Dominikanska Republika	43	8,4
Kuba	35	6,8
Peru	30	5,9
Čile	22	4,3
Argentina	18	3,5
Kostarika	11	2,2
Ekvador	8	1,6
Panama	7	1,4
Sveta Lucija	5	1,0
Jamajka	4	0,8
Urugvaj	4	0,8
Ostale zemlje	52	10,2

Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

3.5. FDI PROJEKTI NA BLISKOM ISTOKU I U AFRICI 2013. – 2021. GODINE


Između 2013. i 2021. godine najavljena su ukupno 442 projekta izravnih stranih ulaganja u sektoru turizma u regiji Bliskog istoka i Afrike, što predstavlja ukupna ulaganja od 34,5 milijardi USD (Tablica 9.). U istom razdoblju u regiji je otvoreno više od 62.428 novih radnih mjesta. Izravna strana ulaganja u sektor turizma porasla su za 70 % u 2021. godini, na ukupno 2,6 milijardi USD. Osim toga, broj izravnih stranih ulaganja u turizmu porastao je na 46, što je povećanje od 84 % u odnosu na 2020. godinu, a broj radnih mjesta u turizmu, također, je bio u porastu, na više od 5.000, što je povećanje od 59 % u odnosu na 2020. godinu. Pearsonov koeficijent korelacije ($r = 0,947$) pokazuje značajnu i pozitivnu međusobnu vezu izravnih stranih ulaganja i otvorenih novih radnih mjesta u turizmu Bliskog istoka i Afrike u razdoblju od 2013. do 2021. godine.

Tablica 9. FDI iz turizma na Bliskom istoku i u Africi 2013. – 2021. godine

Godina	Kapitalna ulaganja		Ukupno projekti		Otvorena radna mjesta	
	Vrijednost, u mlrd. USD	Verižni indeks	Apsolutni broj	Verižni indeks	Apsolutni broj	Verižni indeks
2013.	4,7	-	52	-	5.396	-
2014.	3,5	74,5	37	71,1	3.963	73,4
2015.	1,5	42,8	41	110,8	3.022	76,3
2016.	2,7	180,0	34	82,9	4.588	151,8
2017.	3,1	114,8	36	108,9	6.780	147,8
2018.	6,0	193,5	67	186,1	11.640	171,7
2019.	8,9	148,3	103	153,7	19.200	164,9
2020.	1,5	168,5	26	25,2	2.839	14,8
2021.	2,6	173,3	46	176,9	5.000	176,1
Ukupno	34.5		442		62.428	

Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2019), *Tourism Investment 2018*. Dostupno na: <https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-09/fDi-Tourism-Investment-2018.pdf> [9. listopada 2023.]; fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

Grafikon 5. Otvorena i procijenjena radna mjesta u regiji Bliskog Istoka i Afrike, 2013. - 2021. godine



Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2019), *Tourism Investment 2018*. Dostupno na: <https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-09/fDi-Tourism-Investment-2018.pdf> [9. listopada 2023.]; fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

Vodeća destinacija za izravna strana ulaganja u turizam bili su Ujedinjeni Arapski Emirati sa 148 projekata i 6,8 milijardi USD kapitalnih ulaganja u razdoblju od 2017. i 2021. godine, a svaki je činio 31 % ukupnih regionalnih ulaganja za Bliski istok i Afriku. U istom razdoblju Ujedinjeni Arapski Emirati otvorili su i najviše radnih mjesta u turizmu, više od 12.900, što predstavlja 29 % tržišnog udjela u regiji.

U razdoblju od 2013. do 2021. godine na drugom i trećem mjestu po kapitalnim ulaganjima bili su Saudijska Arabija s 9,96 % ukupnih kapitalni ulaganja u regiji i Maroko sa 6,36 %. Dvije zemlje privukle su zajedno 3,8 milijardi dolara izravnih stranih ulaganja u sektor turizma tijekom petogodišnjeg razdoblja (fDi Intelligence, 2023). Ujedinjeni Arapski Emirati, Maroko i Saudijska Arabija ujedno su tri zemlje koje su otvorile najviše radnih mjesta u turizmu između 2013. i 2021. godine.

Tablica 10. Vodeće zemlje Bliskog istoka i Afrike po broju projekata 2013. – 2021. godine

Zemlja	Broj projekata	Udio turističkih FDI projekata, u %
Ujedinjeni Arapski Emirati	148	31,4
Saudijska Arabija	47	10,0
Maroko	30	6,4
Egipat	30	6,4
Južna Afrika	23	4,9
Oman	16	3,4
Bahrein	16	3,4
Katar	10	2,1
Tanzanija	9	1,9
Tunis	8	1,7
Izrael	8	1,3
Nigerija	6	1,3
Irak	5	1,1
Jordan	5	1,1
Ostale zemlje	111	23,5 %

Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

U regiji Bliskog istoka i Afrike, Ujedinjeni Arapski Emirati bili su glavno odredište za projekte stranih ulaganja u turizmu 2021. godine, s ukupno 19 projekata. Slijede Saudijska Arabija, Maroko, Egipat, Južna Afrika, Oman i Bahrein.

Druga po kapitalnim ulaganjima u regiji Bliskog istoka i Afrike bila je Saudijska Arabija, koja je osigurala 518 milijuna dolara vrijednih kapitalnih ulaganja u turizam u 2021. godini. Otvoreno je više od 1.000 radnih mjesta i šest FDI projekata u 2021. godini. Ujedinjeni Arapski Emirati, također, su bili primarna izvorna zemlja za turistička ulaganja između 2013. i 2021. godine sa 63 turistička projekta stranih ulaganja, što predstavlja 55 % tržišnog udjela u regiji. To je također bilo najveće izvorno tržište za vanjska kapitalna ulaganja (3,9 milijardi USD) koje je stvorilo više od 9.000 radnih mjesta u turizmu. Ujedinjene Arapske Emirate slijedio je Katar po kapitalnim ulaganjima u turizam izvan nacionalnih granica i otvaranju radnih mjesta.

4. ODNOS FDI-A I OTVARANJA NOVIH RADNIH MJESTA U TURIZMU NA GLOBALNOJ RAZINI

Korelacijska analiza omogućuje mjerenje povezanosti FDI-a i broja novootvorenih radnih mjesta u turizmu na globalnoj razini. Pearsonov koeficijent korelacije ukazuje na pozitivnu i jaku vezu ovih dviju varijabli u svim ispitanim regijama svijeta i na globalnoj razini (Tablica 11.). Najslabija povezanost uočena je u Sjevernoj Americi ($r = 0,897$), a najснаžnija u Aziji i na Pacifiku ($r = 0,984$). Na globalnoj razini, Pearsonovo koeficijent korelacije je 0,933.

Tablica 11. Korelacijska matrica izravnih stranih ulaganja i novih radnih mjesta u turizmu, 2013. - 2021. godine

Regija			Kapitalna ulaganja	Radna mjesta
Azija i Pacifik	Kapitalna ulaganja	Pearsonov. koef. kor.	1	0,984**
		Sig. (dvosmjerna)		0,000
		N	9	9
	Radna mjesta	Pearsonov. koef. kor.	0,984**	1
		Sig. (dvosmjerna)	0,000	
		N	9	9
Europa	Kapitalna ulaganja	Pearsonov. koef. kor.	1	0,960**
		Sig. (dvosmjerna)		0,000
		N	9	9
	Radna mjesta	Pearsonov. koef. kor.	0,960**	1
		Sig. (dvosmjerna)	0,000	
		N	9	9

Sjeverna Amerika	Kapitalna ulaganja	Pearsonov. koef. kor.	1	0,897**
		Sig. (dvosmjerna)		0,000
		N	9	9
	Radna mjesta	Pearsonov. koef. kor.	0,897**	1
		Sig. (dvosmjerna)	0,000	
		N	9	9
Latinska Amerika i Karibi	Kapitalna ulaganja	Pearsonov. koef. kor.	1	0,921**
		Sig. (dvosmjerna)		0,000
		N	9	9
	Radna mjesta	Pearsonov. koef. kor.	0,921**	1
		Sig. (dvosmjerna)	0,000	
		N	9	9
Bliski istok i Afrika	Kapitalna ulaganja	Pearsonov. koef. kor.	1	0,947**
		Sig. (dvosmjerna)		0,000
		N	9	9
	Radna mjesta	Pearsonov. koef. kor.	0,947**	1
		Sig. (dvosmjerna)	0,000	
		N	9	9
Svijet	Kapitalna ulaganja	Pearsonov. koef. kor.	1	0,933**
		Sig. (dvosmjerna)		0,000
		N	9	9
	Radna mjesta	Pearsonov. koef. kor.	0,933**	1
		Sig. (dvosmjerna)	0,000	
		N	9	9

** Signifikantnost korelacije na razini 0,01 (dvosmjerna)

Izvor: autorov izračun na temelju podataka raspoloživih u: fDi Intelligence (2019), *Tourism Investment 2018*. Dostupno na: <https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-09/fDi-Tourism-Investment-2018.pdf> [9. listopada 2023.]; fDi Intelligence (2023), *Tourism Investment 2022*. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [9. listopada 2023.]

5. ZAKLJUČAK

Pregled kretanja izravnih stranih ulaganja u turizam na globalnoj razini po pojedinim regijama svijeta u razdoblju od 2013. do 2021. godine prikazan u radu ukazuje na dinamiku izravnih stranih ulaganja u turizmu u pojedinim godinama, pri čemu je najveći broj projekata i kapitalnih ulaganja gotovo u svim regijama realiziran neposredno prije pandemije bolesti COVID-19. Iako se u radu nije istraživalo kretanje turističkih putovanja na globalnoj razini, njihov je rast zasigurno poticatelj privlačnosti turističkog sektora za izravna strana ulaganja, što je pitanje za buduća istraživanja.

U radu se istražuje odnos kapitalnih ulaganja putem izravnih stranih ulaganja u turizam i otvaranje novih radnih mjesta te je utvrđena pozitivna i jaka veza između navedenih varijabli. Istraživanjem se, međutim, ne ulazi dublje u problematiku razloga koji utječu na broj projekata i vrijednost kapitalnih ulaganja u turizam po pojedinim regijama i zemljama (primjerice, stupanj turističke razvijenosti zemlje, zakonodavstvo u zemlji, faza životnog ciklusa turističke destinacije i sl.). Navedene posebnosti utječu i na kauzalnost navedenih varijabli pa bi se trebalo provesti istraživanje za svaku pojedinu zemlju. Ipak, utvrđene veze između kapitalnih ulaganja i novootvorenih radnih mjesta potvrđuju važnost izravnih stranih ulaganja za otvaranje novih radnih mjesta u turizmu. Istraživanje je provedeno do 2021. godine, no svakako bi bilo uputno proširiti istraživanje i na novije razdoblje kako bi se dobio uvid u izravna strana ulaganja u razdoblju nakon pandemije bolesti COVID-19 i njihova veza s novootvorenim radnim mjestima na globalnoj razini.

REFERENCE

1. Asiedu E. (2002) On the determinants of foreign direct investment to developing countries: Is Africa different?, *World Development*, Vol. 30, No. 1, str. 107–119.
2. Bellak C., Leibrecht M. i Damijan J. (2009) Infrastructure endowment and corporate income taxes as determinants of foreign direct investment in central and eastern European countries, *World Economy*, Vol. 32, No. 2, str. 267–290.
3. Bezić, H., Nikšić Radić, M. i Kandžija, T. (2010) Foreign Direct Investments in the Tourism Sector of the Republic of Croatia, *Valahian Journal of Economic Studies*, Vol. 1, No. 15, str. 21–28.
4. Bezić, H. i Nikšić Radić, M. (2017) Tourism foreign direct investment led tourism gross value added: a co-integration and causality analysis of Croatian tourism, *Economic Research*, Vol. 30, No. 1, str. 1443–1460,
5. Cambazoglu B. i Simay Karaalp H. (2014) Does foreign direct investment affect economic growth? The case of Turkey, *International Journal of Social Economics*, Vol. 41, No. 6, str. 434–449.
6. Chakrabarti A. (2001) The determinants of foreign direct investments: Sensitivity analyses of cross-country regressions, *Kyklos*, Vol. 54, No. 1, str. 89–114.
7. Coskun R. (2001) Determinants of direct foreign investment in Turkey, *European Business Review*, Vol. 13, No. 4, str. 221–227.
8. Casi L. i Resmini L. (2010) Evidence on the determinants of foreign direct investment: The case of EU regions, *Eastern Journal of European Studies*, Vol. 1, No. 2, str. 93–118.
9. Dhingra N. i Sidhu H. (2011) Determinants of foreign direct investment inflows to India, *European Journal of Social Sciences*, Vol. 25, No. 1, str. 21–31.

10. Dunning J. H. i Lundan S. M. (2008) *Multinational enterprises and the global economy* (2nd ed.), Edward Elgar Publishing.
11. fDi Intelligence (2019) Tourism Investment 2018. <https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-09/fDi-Tourism-Investment-2018.pdf> [15. travnja 2023.]
12. fDi Intelligence (2020) Tourism Investment 2019. <https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-09/fDi-Tourism-Investment-2019-Financial-Times.pdf> [15. travnja 2023.]
13. fDi Intelligence (2023) Tourism Investment 2022. Dostupno na: <https://www.unwto.org/investment/tourism-investment-report-2022> [15. travnja 2023.]
14. Galičić, V. i Laškarin, M. (2016) *Principi i praksa turizma i ugostiteljstva*. Fakultet za menadžment u turizmu i ugostiteljstvu: Opatija.
15. Igošina V. (2015) FDI to EU15 and new member states: Comparative analysis of inflow determinants, *Prague Economic Papers*, Vol. 24, No. 3, 260–273.
16. IMF (1993) *Balance of payments manual: Fifth edition (BPM5)* [Online]. Dostupno na: <https://www.imf.org/external/pubs/ft/bopman/bopman.pdf> [15. studenoga 2024.]
17. Janicki H. i Wunnavia P. (2004) Determinants of foreign direct investment: Empirical evidence from EU accession candidates, *Applied Economics*, Vol. 36, No. 5, str. 505–509.
18. Karlsson, S., Lundin, N., Sjöholm, F. i He, P. (2009). Foreign firm and Chinese employment, *World Economy*, Vol. 32, No. 1, str. 178–201., <https://doi.org/10.1111/j.1467-9701.2009.01162.x>
19. Khoshnevis Yazdi, S., Homa Salehi, K. i Soheilzad, M. (2015) The relationship between tourism, foreign direct investment and economic growth: Evidence from Iran, *Current Issues in Tourism*, Vol. 19, str. 1–11, doi:10.1080/13683500.2015.1046820
20. Leonardo B., Iulian P., Adela S. i Andreea Daniela M. (2018) Sentiment, perception and policy determinants of foreign direct investment to European developing countries, *Economic Computation and Economic Cybernetics Studies and Research*, Vol. 52, No. 2, str. 69–85.
21. Mah J. S. i Yoon S. (2010) Determinants of FDI Flows into Indonesia and Singapore, *International Area Review*, Vol. 13, No. 1, str. 63–73.
22. Mamoon, M. i Rahman, A. F. M. A. (2016) Effects of Foreign Direct Investment (FDI) on Bangladeshi Labor Market, *World Review of Business Research*, Vol. 6, No. 3, str. 46–60.
23. Moosa I. A. (2009) The determinants of foreign direct investment in MENA countries: An extreme bounds analysis, *Applied Economics Letters*, Vol. 16, No. 15, str. 1559–1563.
24. Othman, R., Salleh, N.H.M. i Sarmidi, T. (2012) Analysis of Causal Relationship Between Tourism Development, Economic Growth and Foreign Direct Investment: an ARDL Approach, *Journal of Applied Sciences*, Vol. 12, No. 12, str. 1245–1254, doi:10.3923/jas/2012.1245.1254
25. Özkan-Günay E. (2011) Determinants of FDI inflows and policy implications: A comparative study for the enlarged EU and candidate countries, *Emerging Markets Finance and Trade*, Vol. 47, No. 4, str. 71–85.

26. Rodríguez X. i Pallas J. (2008) Determinants of foreign direct investment in Spain. *Applied Economics*, Vol. 40, No. 19, str. 2443–2450.
27. Saini N. i Singhania M. (2018) Determinants of FDI in developed and developing countries: A quantitative analysis using GMM, *Journal of Economic Studies*, Vol. 45, No. 2, str. 348–382.
28. Siddharthan, N.S. i Karayanan, K. (2020) *FDI, Technology and Innovation*, Springer. Dostupno na: <https://link.springer.com/book/10.1007/978-981-15-3611-3> [4. veljače 2024.]
29. Sokhanvar, A. (2022) The role of tourism and FDI in the economic growth of EU11 countries, *Tourism and Hospitality Management*, Vol. 28, No. 2, str. 343–359.
30. Stack M., Ravishankar G. i Pentecost E. (2017) Foreign direct investment in the eastern European countries: Determinants and performance, *Structural Change and Economic Dynamics*, Vol. 41, No. 1, str. 86–97.
31. Tang D. (2017) The determinants of European Union (EU) foreign direct investments in the EU Countries from central and eastern Europe during 1994–2012, *Comparative Economic Research*, Vol. 20, No. 1, 75–99.
32. UNWTO (2001) *Enzo Paci papers on measuring the economic significance of tourism*, Vol. 1, UNWTO: Madrid.
33. UNWTO (2020) Tourism Investment Report, <https://www.unwto.org>
34. UNWTO (2024) International Tourism to Reach Pre-Pandemic Levels in 2024. Dostupno na: <https://www.unwto.org/news/international-tourism-to-reach-pre-pandemic-levels-in-2024> [17. veljače 2024.]
35. Villaverde J. i Maza A. (2015) The determinants of inward foreign direct investment: Evidence from the European regions, *International Business Review*, Vol. 24, No. 2, str. 209–223.
36. Wei W. (2005) China and India: Any difference in their FDI performances?, *Journal of Asian Economics*, Vol. 16, No. 4, str. 719–736.
37. Wijeweera A. i Mounter S. (2008) A VAR analysis on the determinants of FDI inflows: The case of Sri Lanka, *Applied Econometrics and International Development*, Vol. 8, No. 1, str. 189–198.
38. The World Bank (2022) Tourism and Competitiveness. Dostupno na: <https://world-bank.org/en/topic/competitiveness/brief/tourism-and-competitiveness> [7. veljače 2024.].
39. WTO (1996), *News—‘Trade and foreign direct investment’* [Online]. Dostupno na: https://www.wto.org/english/news_e/pres96_e/pr057_e.htm [15. kolovoza 2024.].
40. Zhao, J., Yang, D., Zhao, X. i Lei, M. (2003) Tourism industry and employment generation in emerging seven economies: evidence from novel panel methods, *Economic Research*, Vol. 36, No. 3, 2206471, str. 1–17., <https://doi.org/10.1080/1331677X.2023.2206471>
41. Zheng P. (2009) A comparison of FDI determinants in China and India, *Thunderbird International Business Review*, Vol. 51, No. 3, str. 263–279.

OVERVIEW OF FOREIGN DIRECT INVESTMENT IN TOURISM GLOBALLY

Full Professor Elvis Mujačević, PhD

University of Rijeka, Faculty of Tourism and Hospitality Management

e-mail: elvism@fthm.hr

ABSTRACT

Foreign investment plays an important role in job creation as it boosts employment in various sectors related to tourism (hospitality, transportation, trade, etc.). Higher employment rates in turn lead to an improvement in the living standards of local communities. With this in mind, it is necessary to examine FDI flows by world region and analyse the impact of FDI on job creation. An overview of global foreign direct investment by individual world regions (Asia-Pacific, Europe, North America, Latin America and the Caribbean, Middle East and Africa) from 2013 to 2021 shows the dynamics of direct investment by individual years, with the largest number of projects and capital investments realized in almost all regions shortly before the Covid-19 pandemic. Using descriptive statistics, the conclusion is that there is a significant positive and strong correlation between foreign direct investment and newly created jobs in all regions of the world.

Keywords: *tourism, job creation, foreign direct investment*

JEL classification: F01, F21, L83, 05, Z3, Z32

RAČUNOVODSTVO POSLOVNIH KOMBINACIJA DRUŠTAVA POD ZAJEDNIČKOM KONTROLOM

dr. sc. Branka Remenarić

Zagrebačka škola ekonomije i managementa
e-mail: bremenar@zsem.hr

doc. dr. sc. Ivan Čevizović

Čevizović Ivan j.t.d., Zagreb
e-mail: ivan.cevizovic@cevizovic.eu

izv. prof. dr. sc. Branimir Skoko

Sveučilište u Mostaru, Ekonomski fakultet Sveučilišta u Mostaru
e-mail: branimir.skoko@ef.sum.ba

SAŽETAK

Poslovanje društava, kao samostalnih subjekata, različito je od poslovanja unutar grupe. Poslovanje unutar grupe sa sobom nosi posebne izazove. To posebno postaje izraženo u slučaju restrukturiranja grupa, kada se provode i statusne promjene, odnosno dolazi do pripajanja i/ili spajanja društava unutar grupe. Ovakve transakcije izazov su i kada je riječ o međusobno neovisnim društvima, odnosno društvima koja nisu pod kontrolom iste matice. Međutim, izazov adekvatnog računovodstvenog tretmana postaje tim veći ako se radi o kombinacijama unutar grupe. To je zato što se statusne promjene unutar grupe često odvijaju bez naknade za stjecanje, ili je ona različita od fer vrijednosti. Ništa manje nije izazovno ni pitanje samih razloga za statusnu promjenu. Značaj ovakvih transakcija upravo potvrđuje činjenica da se već niz godina radi na razvoju odgovarajućeg standarda financijskog izvještavanja koji bi na odgovarajući način obuhvatio ovo područje. Svrha ovog članka jest dati pregled stanja u postojećem okviru financijskog izvještavanja, odnosno istražiti i prikazati aktualne aktivnosti na izradi odgovarajućeg računovodstvenog okvira na međunarodnoj razini.

Ključne riječi: zajednička kontrola, stjecanje, MSFI, poslovne kombinacije, porez

JEL klasifikacija: F38, M41, M48, H21, H25

1. UVOD

Poslovanje pojedinih grupa uređeno je težnjom za ostvarenjem postavljenih ciljeva. Ostvarenje ovih ciljeva nije uvijek moguće realizirati samo kroz operativno poslovanje, već je potrebno uključiti i složenije operacije koje se odnose i na poslovne kombinacije. Ovo se ponekad odvija i kao sastavni dio restrukturiranja grupe. Posljedica je pripajanje, odnosno spajanje među pojedinim članicama grupe. Ovakve transakcije otvaraju pitanje prikladnog računovodstvenog tretmana. Naime, ključno je pitanje koliko je ovakvo pripajanje koje se događa među članicama iste grupe usporedivo s, primjerice, pripajanjem prethodno nepovezanog društva? Naime, već na prvi pogled nameće se pitanje određivanja troška stjecanja, koji ne mora nužno biti usporediv s poimanjem troška stjecanja u transakciji koja ne uključuje društva pod zajedničkom kontrolom, transakciji između nepovezanih društava, gdje je razumno pretpostaviti da je cijela transakcija utemeljena na tržišnim osnovama. Osim toga, nameće se pitanje vrednovanja imovine i obveza uključenih u ovakvu poslovnu kombinaciju jer, kao što trošak stjecanja ne odražava nužno fer vrijednost, isto tako ni stjecanje imovine i preuzimanje obveza ne moraju nužno dovesti do promjene u njihovu mjerenju. To osobito dolazi do izražaja s aspekta konsolidiranih financijskih izvještaja ovakvih grupa jer učinak restrukturiranja grupe, zapravo nije promijenio ekonomsku snagu, odnosno, imovinu pod kontrolom grupe.

Polazeći od ovog problema, neminovno je potrebno razmotriti ekonomsku bit transakcije jer iako, u pravnom smislu, potpuno identična promjena statusa, može u svojoj ekonomskoj biti odražavati i biti uvjetovana potpuno različitim razlozima. Posljedično, treba prepoznati i prikladan računovodstveni model.

S obzirom na značaj i broj ovakvih transakcija, ove transakcije i odgovarajući metodološki okvir za njihovo tretiranje predmet su brojnih analiza i istraživanja, a u novije vrijeme rezultiraju i naporima na razvoju novog standarda financijskog izvještavanja koji ima za cilj uniformno urediti ovo područje.

Svrha ovog rada jest istražiti postojeće stanje računovodstvenog okvira za poslovne kombinacije društava pod zajedničkom kontrolom na nacionalnoj i međunarodnoj razini te analizirati trenutačno stanje razvoja modela za poslovne kombinacije pod zajedničkom kontrolom.

Nastavno na navedeno, rad će obuhvatiti i analizu postojećih istraživanja o navedenoj problematici poslovnih kombinacija društava pod zajedničkom kontrolom. Stoga je pregled postojećih istraživanja prikazan u drugom naslovu.

Treći naslov donosi prikaz postojećeg okvira za financijsko izvještavanje poslovnih kombinacija društava pod zajedničkom kontrolom analizirano kroz MSFI/HSFI odredbe. Prije zaključka, objašnjava se novi IASB projekt u području poslovnih kombinacija društava pod zajedničkom kontrolom.

2. POSTOJEĆA ISTRAŽIVANJA

Istraživanja o poslovnim kombinacijama pod zajedničkom kontrolom često su povezana s općenitim istraživanjima i poslovnim kombinacijama. Kako je utvrdila Janowicz (2017), unatoč njihovoj složenosti, o poslovnim kombinacijama društava pod zajedničkom kontrolom ne piše se često. Drugim riječima, vrlo malo radova odnosi se na praktične i teorijske aspekte računovodstva ovog specifičnog oblika poslovnih kombinacija. Određena se razina istraživanja tek usputno odnosi na poslovne kombinacije pod zajedničkom kontrolom ili se odnose na analizu prijedloga Odbora za međunarodne računovodstvene standarde (IASB) za razvoj računovodstvenog modela poslovnih kombinacija društava pod zajedničkom kontrolom (primjerice, Fiume *et al.* (2015), Bellandi *et al.* (2021) i Polo-Garrido i Meliá-Martí (2021). Povezana istraživanja, sa širim kontekstom poslovnih kombinacija, uglavnom se odnose na istraživanje primjenjivih metoda za poslovne kombinacije i njihova razvoja tijekom povijesti. U ovoj povijesti mogu se istaknuti tri glavne metode poslovnih kombinacija (Polo-Garrido i Meliá-Martí (2021, str. 2523): metoda kupnje, metoda udruživanja (ili spajanja) interesa i metoda novog početka.

Ove metode mogu se identificirati i iz Međunarodnih računovodstvenih standarda, odnosno Međunarodnih standarda financijskog izvještavanja, kao njihova nastavka. Naime, prve dvije metode, metoda kupnje i metoda udruživanja interesa, bile su temeljne metode poslovnih kombinacija u MRS 22 – *Poslovne kombinacije*, koji je 2004. godine zamijenjen s MSFI 3 – *Poslovne kombinacije*. Iako naziv prethodnog i potonjeg standarda ostaje nepromijenjen, računovodstveni pristup poslovnim kombinacijama bitno je različit. Prema definiciji iz točke 8. MRS 22 – *Poslovne kombinacije*, poslovno spajanje jest dovođenje samostalnih poduzeća u jedan ekonomski subjekt kao rezultat objedinjavanja ili dobivanja kontrole jednog poduzeća nad neto imovinom i poslovanjem drugog poduzeća. Nadalje, stjecanje je poslovno spajanje u kojem jedno od poduzeća – stjecatelj, dobiva kontrolu nad neto imovinom i poslovanjem drugog poduzeća – stečeno poduzeće u zamjenu za prijenos imovine, preuzete obveze ili emitiranu glavicu. Udruživanje interesa jest poslovno spajanje u kojem di-

oničari spajajućih poduzeća spajaju kontrolu nad svojom cjelokupnom ili gotovo cjelokupnom neto imovinom i poslovanjem kako bi se postiglo neprekidno zajedničko sudjelovanje u rizicima i koristima spojenog subjekta, tako da nijednu stranku nije moguće raspoznati kao stjecatelja.

Metoda spajanja rezultirala je određenom asimetrijom u podacima u financijskim izvještajima. Naime, tek je dio imovine i obveza, i to onih stečenika, mjereno po fer vrijednosti, pa je objedinjavanje istih stranaka stjecatelja i stečenika rezultiralo različitim mjerenjem, a time i mogućim značajnim skrivenim rezervama, što može dovesti u pitanje i ispunjenje temeljnog cilja financijskog izvještavanja – osigurati informacije o financijskom položaju, financijskoj uspješnosti i novčanim tokovima subjekta, koje su korisne širokom krugu korisnika pri donošenju ekonomskih odluka (MRS 1).

Nasuprot tomu, udruživanje interesa, kao metoda koja nastavlja knjigovodstvene, dakle povijesne vrijednosti kod svih sudionika poslovnog spajanja, također ima određene nedostatke. Prema Nurnberg i Sweeney (2007) korištenje povijesnih knjigovodstvenih vrijednosti omogućuje menadžerima da naprave goleme akvizicije, da ih zabilježe uz djelić njihove cijene, prijave manje troškova u narednim razdobljima i ostave jedva trag onoga što je možda nepromišljena ili pretjerano skupa akvizicija u postakvizicijskim financijskim izvještajima.


Metoda novog početka ostala je samo kao mogući koncept. Naime, ova metoda, po kojoj se poslovno spajanje shvaća kao novi početak novog subjekta, bez obzira na činjenicu da s pravne strane jedan „preživljava“ poslovnu kombinaciju, i u tu se svrhu sva imovina i obveze ponovno mjere po njihovoj fer vrijednosti na datum stjecanja, bila je i ostala tek dio razmatranja u Fazi I IASB projekta poslovnih kombinacija, a koji je rezultirao Međunarodnim standardom financijskog izvještavanja 3 – *Poslovne kombinacije* (IASB 2011).

3. POSTOJEĆI OKVIR ZA FINANCIJSKO IZVJEŠTAVANJE POSLOVNIH KOMBINACIJA DRUŠTAVA POD ZAJEDNIČKOM KONTROLOM

Primjereni računovodstveni tretman poslovnih kombinacija društava pod zajedničkom kontrolom uvjetovan je primjenjivim okvirom financijskog izvještavanja koji je u primjeni u pojedinoj državi. Kako su poduzetnici u Republici Hrvatskoj dužni primjenjivati odredbe Međunarodnih standarda financijskog izvještavanja ili Hrvatskih standarda financijskog izvještavanja, ovisno o njho-


voj veličini, činjenici da kotiraju na burzi ili su bili u poziciji sami izabrati, treba analizirati odredbe primjenjivog seta standarda u pojedinom slučaju. Osim toga, upravo odredbe Međunarodnih standarda financijskog izvještavanja daju dobar okvir za međunarodni pogled na računovodstveni tretman ovih transakcija. Isto tako, Hrvatski standardi financijskog izvještavanja daju dobar uvid u nacionalni pristup financijskom izvještavanju o ovim transakcijama, ali i, zbog činjenice da je hrvatsko zakonodavstvo usklađeno sa zakonodavstvom EU-a, ukazuju i na europski okvir za financijsko izvještavanje o ovim transakcijama. Prije svega potrebno je definirati poslovnu kombinaciju za potrebe financijskog izvještavanja. Prema MSFI 3, poslovna kombinacija označava transakciju ili drugi događaj u kojem stjecatelj stječe kontrolu nad jednim ili više poslovanja. Za ove transakcije MSFI 3 predviđa primjenu metode stjecanja, odnosno zahtijeva da stjecatelj, na datum stjecanja, prizna, odvojeno od *goodwill*, prepoznatljivu stečenu imovinu, preuzete obveze i svaki manjinski udio u stečeniku.

Slika 1. Prikaz strukture prije i nakon poslovne kombinacije



Izvor: prikaz autora. Kratica OD označava ovisno društvo.

Slika 2. Prikaz strukture prije i nakon poslovne kombinacije društava pod zajed-



Izvor: prikaz autora. Kratica OD označava ovisno društvo.

Navedena transakcija predstavlja odnos između dvaju nepovezanih (samostalnih) društava koja, kao matice, ostvaruju kontrolu nad grupom (M1 i M2). Problem nastaje kada se transakcija događa između društava pod zajedničkom kontrolom jer u svojoj biti ne odražava stvarno namjeru stjecanja nekog poslovanja koje do tada nije bilo dio grupe.

Kako je vidljivo iz prikaza jedne moguće transakcije koja obuhvaća poslovnu kombinaciju društava pod zajedničkom kontrolom, grupa, kao cjelina, ostala je nepromijenjena. Međutim, iz perspektive ovisnih društava 1 i 2, koja su ujedno i međumatice prije promjene (poslovne kombinacije kojom ovisno društvo 2 stječe kontrolu nad ovisnim društvom 3), dolazi do značajne promjene. Naime, ovisno društvo 2 proširuje grupu koju uključuje u svoje konsolidirane financijske izvještaje, dok ovisno društvo 1 prestaje biti matica jer gubi kontrolu nad jedinim ovisnim društvom koje je prethodno imalo. Posljedično, s aspekta konsolidiranih financijskih izvještaja potpuno je jasan računovodstveni tretman ove transakcije – transakcija mora ostati potpuno neutralna na konsolidirane financijske izvještaje jer sve što se dogodi unutar grupe naprosto se eliminira za potrebe konsolidacije. Međutim, problem ostaje adekvatan tretman u odvojenim financijskim izvještajima. Drugim riječima, potrebno je pronaći odgovarajući odgovor na pitanje: Treba li nastali ekonomski fenomen biti neutralan i na odvojene financijske izvještaje?

Prije toga treba svakako odrediti obuhvat transakcija koje se smatraju transakcijama pod zajedničkom kontrolom. Prema točki B1. iz Dodatka B MSFI 3 – *Poslovna spajanja*, poslovno spajanje društava ili poslovanja pod zajedničkom kontrolom jest poslovno spajanje u kojem su sva društva ili sva poslovanja koja se spajaju pod krajnjom kontrolom iste strane ili strana i prije i nakon poslovnog spajanja, a ta kontrola nije privremena. Prema definiciji iz MSFI 10 – *Konsolidirani financijski izvještaji*, kontrola je definirana kao ona situacija u kojoj je investitor, na temelju svog sudjelovanja u nekom subjektu izložen varijabilnom prinosu, odnosno ima prava na njega kao rezultat svoje povezanosti sa subjektom u koji je izvršeno ulaganje te ima mogućnost utjecati na te prinose kroz svoju moć nad subjektom u koji je izvršeno ulaganje. Postojanje ovakve kontrole nad navedenim društvima uključenima u transakciju pripajanja upravo na navedeni način najbolje dokazuje uključivanje ovih društava u istu vršnu konsolidaciju u prethodnim razdobljima.

3.1. MEĐUNARODNI STANDARDI FINACIJSKOG IZVJEŠTAVANJA

Međunarodni standardi financijskog izvještavanja relevantni su za međunarodni pogled za ovu vrstu transakcija. Ove standarde donosi Odbor za međunarodne računovodstvene standarde koji ima dugu povijest. Počeci sežu u 1973. godinu kada profesionalna računovodstvena tijela Australije, Kanade, Francuske, Njemačke, Japana, Meksika, Nizozemske, Ujedinjenog Kraljevstva/

Irske i Sjedinjenih Američkih Država formiraju Komitet za međunarodne računovodstvene standarde (IASB) kako bi razvili osnovne računovodstvene standarde i promovirali njihovo prihvaćanje u cijelom svijetu (IASB, 2023).

Tablica 1. Upotreba MSFI-ja kao okvira financijskog izvještavanja u svijetu.

Regija	Broj država u regiji	Države koje zahtijevaju MSFI za sve ili većinu subjekata od javnog interesa	Države koje zahtijevaju MSFI u odnosu na ukupan broj država	Države koje dopuštaju ili zahtijevaju MSFI za barem neke (ali ne sve ili većinu) subjekte od javnog interesa	Države koje ne dopuštaju, niti zahtijevaju MSFI za subjekte od javnog interesa
Europa	44	43	98 %	1	0
Afrika	39	37	95 %	1	1
Srednji istok	13	12	92 %	1	0
Azija i Oceanija	35	28	80 %	2	5
Amerike	37	26	70 %	9	2
Ukupno	168	147	87,5 %	13	8
Kao % od 168	100 %	87,5 %		7,70 %	4,80 %

Izvor: IASB (2023b) Who uses IFRS Accounting Standards?, <https://www.ifrs.org/use-around-the-world/use-of-ifrs-standards-by-jurisdiction/#analysis-of-the-168-profiles>

Kako je razvidno iz prikazane tablice, standardi MSFI kao okvir financijskog izvještavanja široko su rasprostranjeni diljem svijeta. U Europi je ova rasprostranjenost najveća, čak 98 % država zahtijeva ili dopušta primjenu MSFI-ja kao okvira financijskog izvještavanja (bar) za društva od javnog interesa. Tome svakako doprinosi i činjenica da je Europska unija prihvatila ove standarde.

Unutar MSFI okvira, već spomenuti MSFI 3, iako definira spajanje društava pod zajedničkom kontrolom, isključuje iz svog djelokruga i ne odnosi se na poslovna spajanja društava ili poslovanja pod zajedničkom kontrolom (točka 2. MSFI 3). Kako Međunarodni standardi financijskog izvještavanja ne sadrže posebne odredbe o računovodstvenom tretmanu ovakvih transakcija, društvo je dužno prilikom usvajanja računovodstvene politike za ovu transakciju razmotriti odredbe MRS 8 – *Računovodstvene politike, promjene računovodstvenih procjena i pogreške*. Točka 10. navedenog standarda uređuje da u slučaju nepostojanja standarda ili tumačenja koje je posebno primjenjivo na transakciju, drugi događaj ili okolnost, menadžment će sam prosuditi pri razvoju i primjeni računovodstvenih politika koje će rezultirati informacijama koje su:

- a) važne i potrebne korisniku pri donošenju ekonomskih odluka
- b) pouzdane tako da financijski izvještaji:
 - i. vjerno predočuju financijski položaj, financijsku uspješnost i novčane tokove subjekta
 - ii. odražavaju ekonomsku bit transakcija, drugih događaja i uvjeta, a ne samo zakonsku formu
 - iii. neutralni su i nepristrani
 - iv. temeljeni su na opreznosti
 - v. potpuni su u svim važnim aspektima.

Pri ovom prosuđivanju potrebno je razmotriti primjenjivost sljedećih izvora po padajućem redoslijedu (točka 11. MRS 8):

- a) zahtjeve i upute u MSFI-jevima koja obrađuju slična ili povezana pitanja
- b) definicije, kriterije priznavanja i koncepte mjerenja imovine, obveza, prihoda i rashoda iz Okvira.

Isto tako, društvo također može razmotriti najnovije objave drugih tijela koja kreiraju standarde, a koriste sličan konceptualni okvir za razvijanje računovodstvenih standarda, drugu stručnu literaturu i prihvaćenu praksu u grani, u razmjeru u kojem to ne dovodi do konflikta s prethodno navedenim izvorima (točka 12. MRS 8).

Slijedeći hijerarhiju MRS 8 pri izboru računovodstvenih politika, potrebno je analizirati i pristupe sadržane u drugim setovima standarda financijskog izvještavanja. Jedno od tijela koje izdaje računovodstvene standarde jest i Odbor za financijsko-računovodstvene standarde (FASB). Prema FASB standardu SFAS No. 141(R) *Business Combinations* spajanja društava pod zajedničkom kontrolom isključena su iz djelokruga standarda, ali Dodatak D ovog standarda sadrži određene upute o računovodstvu ovih transakcija. Točka D9 zahtijeva da stjecatelj u transakciji društava pod zajedničkom kontrolom prizna stečenu imovinu i obveze po njihovim knjigovodstvenim vrijednostima iz financijskih izvještaja na datum transakcije.

Kao potvrdu potonjeg pristupa treba spomenuti i Odluku EECS/0508-04 Odbora europskih regulatora vrijednosnih papira (CESR) (2008) kojom je potvrđeno da je primjena metode udruživanja interesa na poslovne kombinacije društava pod zajedničkom kontrolom, sukladno FASB-ovim standardima, prihvatljiva za izdavatelje koji primjenjuju MSFI.

3.2. HRVATSKI STANDARDI FINANCIJSKOG IZVJEŠTAVANJA

Hrvatski standardi financijskog izvještavanja predstavljaju nacionalne standarde primjenjive u Republici Hrvatskoj. Isti se odnose na mikro, male i srednje poduzetnike, odnosno one koji nisu obveznici primjene MSFI-ja.

Prema relevantnim Hrvatskim standardima financijskog izvještavanja, ključni su zahtjevi HSFI 2 – *Konsolidirani financijski izvještaji*. Točkom 2.34. HSFI 2 uređen je računovodstveni tretman poslovnih spajanja poduzetnika ili poslovanja pod zajedničkom kontrolom. Ovdje je ključan upravo dio koji se odnosi na poslovanje. Naime, poslovanje podrazumijeva da postoje neki *inputi* i procesi koji se primjenjuju na te *inpute*, a koji imaju sposobnost stvaranja *outputa*. Drugi važan segment koji je potrebno utvrditi jest da postoji zajednička kontrola. Prema točki 2.34. HSFI 2, zajednička kontrola znači da su svi poduzetnici ili poslovanja pod krajnjom kontrolom iste strane ili strana i prije i nakon poslovnog spajanja, a ta kontrola nije privremena.

Za tretman dijela koji se odnosi na stavke kapitala, točka 2.34. HSFI 2 propisuje da se prihodi i rashodi i novčani tokovi poslovanja koje prestaje ostvariti do datuma stjecanja u poslovnom spajanju poduzetnika pod zajedničkom kontrolom unutar grupe uključuju u zadržanu dobit izvještajnog poduzetnika. Nadalje, datum stjecanja definiran je kao datum koji proizlazi iz ugovora i predstavlja datum od kojeg se prihodi i rashodi i novčani tokovi poslovanja koji prestaju uključuju u financijske izvještaje izvještajnog poduzetnika.

Ovakav pristup sadržan u HSFI-ju usporediv je i s pristupom koji se primjenjuje na razini Europske unije, sukladno Direktivi 2013/34/EU (2013). Sukladno tome, može se zaključiti da je ovakav pristup relevantan diljem Europske unije, ali za ona društva koja nisu obveznici primjene MSFI-ja. Kako navedeni pristup osigurava neutralnu transakciju poslovne kombinacije društava pod zajedničkom kontrolom, u slučaju pravnog pripajanja ili spajanja, valja istaknuti i porezne posljedice ovakvih transakcija.

Prema odredbama članka 19. Zakona o porezu na dobit proizlazi da je, u slučaju statusnih promjena u kojima ne dolazi do promjene u procjeni vrijednosti imovine i obveza, moguće ostvariti porezno neutralnu transakciju pripajanja. Pri tome je ključno da se radi o statusnim promjenama koje su uređene posebnim propisom. Ovakav pristup proizlazi iz regulative Europske unije, točnije Direktive Vijeća 2009/133/EZ.

3.3. POSTOJEĆA PRAKSA ZA RAČUNOVODSTVO DRUŠTAVA POD ZAJEDNIČKOM KONTROLOM

Prethodno je prikazan metodološki okvir na nacionalnoj i međunarodnoj razini za obuhvat poslovnih kombinacija društava pod zajedničkom kontrolom. Pri tome se može zaključiti:

- a) U okviru MSFI-ja postoji definicija poslovnih kombinacija društava pod zajedničkom kontrolom, ali nema uputa o adekvatnom obuhvatu navedenih transakcija.
- b) Njih je potrebno provesti prema općim odredbama za slučaj kada ne postoje adekvatni standardi (primjena hijerarhije iz MRS 8).
- c) Primjena navedenoga može dovesti do različitih rješenja, primjerice:
 - i. analogijom je moguće primijeniti odredbe MSFI 3, iako on isključuje ovu vrstu transakcija iz svog djelokruga
 - ii. primijeniti modele razvijene u drugim, usporedivim, okvirima financijskog izvještavanja.
- d) Na nacionalnoj razini (i razini Europske unije) postoji određen model obuhvata ovih transakcija, ali on nije dovoljno detaljno razrađen, što može rezultirati različitom interpretacijom i primjenom.

O značaju navedenog problema, kao i različitim praksama koje se primjenjuju nabolje svjedoči istraživanje Europske savjetodavne skupine za financijsko izvještavanje (EFRAG). EFRAG je pokrenuo raspravu o računovodstvu društava pod zajedničkom kontrolom. U listopadu 2011. godine EFRAG je objavio *Discussion Paper* u kojemu je analizirano postojeće stanje u računovodstvenoj praksi, a u prosincu 2012. godine objavljeni su rezultati rasprave. EFRAG (2011) je došao do zaključka da se u praksi primjenjuju dvije metode:

- a) spajanje po knjigovodstvenim vrijednostima i
- b) primjena MSFI 3, iako MSFI 3 isključuje iz svog djelokruga ovakve transakcije.

U nastavku svog istraživanja EFRAG (2012) je utvrdio da većina ispitanika smatra da bi trebali postojati različiti pristupi ovisno o prirodi poslovnih kombinacija društava pod zajedničkom kontrolom, s obzirom na to da bi u određenim slučajevima računovodstvo stjecanja bilo prikladnije, dok bi u drugim slučajevima ili računovodstvo prethodnika ili model 'novog početka' pružili više korisnih informacija. Slijedom sličnih istraživanja, IASB je dodao na svoj dnevni red još 2007. godine ovu temu za buduće rasprave, i potencijalno razvoj odgovarajućeg standarda.

4. NOVI OKVIR ZA FINACIJSKO IZVJEŠTAVANJE POSLOVNIH KOMBINACIJA DRUŠTAVA POD ZAJEDNIČKOM KONTROLOM

Iako je IASB ovaj projekt dodao na svoj dnevni red na sastanku u prosincu 2007., tada nije bilo rasprava. U prosincu 2012., kao dio svog odgovora na konzultacije o Agendi 2011., IASB je službeno ponovno aktivirao ovaj projekt kao istraživački projekt samo za IASB (2011b). Dokument za raspravu objavljen je 30. studenoga 2020., a komentari su zatraženi do 1. rujna 2021. U dokumentu za raspravu IASB (2020) je postavio kao ključne spoznaje na temelju kojih se promišlja o projektu:


- a) Raznolikost u praksi otežava investitorima razumijevanje učinaka ovih transakcija i uspoređivanje društava koja imaju ovakve transakcije.
- b) Ove kombinacije uobičajene su u mnogima državama širom svijeta, posebno u ekonomijama u razvoju.
- c) Razvijanje zahtjeva za izvještavanje za te bi kombinacije trebalo biti prioritet, posebno u odnosu na društva koja kotiraju ili se pripremaju za uključivanje.

Slijedom toga, IASB je, na temelju prethodnih istraživanja, zaključio da odgovarajući model za poslovne kombinacije društava pod zajedničkom kontrolom mora biti jedan od triju mogućih (IASB 2020):

- a) metoda knjigovodstvene vrijednosti – nastavak knjigovodstvenih vrijednosti, u svim slučajevima
- b) metoda stjecanja (MSFI 3) u svim slučajevima, osim ako trošak primjene nadilazi koristi (cost/benefit test)
- c) jedna od prethodnih dviju, ovisno o okolnostima – jedan model ne odgovara svima – za neke poslovne kombinacije pod zajedničkom kontrolom treba koristiti metodu stjecanja, a za ostale treba koristiti metodu knjigovodstvene vrijednosti.

Zaključak IASB-a jest da je posljednji model, izbor metode koji ovisi od slučaja do slučaja, najbolji. Sukladno tome IASB (2020) je predložio da se izbor između metoda odvija na temelju sljedećeg stabla odlučivanja.


Grafikon 1. Sažetak preliminarog stajališta IASB-a



Izvor: IASB (2020) Business Combinations under Common Control. Snapshot, <https://www.ifrs.org/content/dam/ifrs/project/business-combinations-under-common-control/snapshot-dp-bcucc-november-2020.pdf>.

Kako ovakav pristup može rezultirati naknadom različitom od neto imovine, pitanje koje ostaje za dodatno razmatranje jest priznavanje ovog učinka, iz čega se nameću dva moguća rješenja. Jedna opcija, koja je izgledna za primjenu metode stjecanja, odnosi se na priznavanje *goodwill*, dok je druga, izgledna za metodu knjigovodstvene vrijednosti, da se razlika tretira kao izravno smanjenje kapitala.

Grafikon 2. Moguće razlike između naknade i pristupa mjerenju neto imovine



Izvor: rekapitulacija autora prema IASB (2020) Business Combinations under Common Control. Snapshot, <https://www.ifrs.org/content/dam/ifrs/project/business-combinations-under-common-control/snapshot-dp-bcucc-november-2020.pdf>.

Kako je razvidno iz prikazanog, ova razlika nastaje kada naknada odgovara naknadi mjerenoj prema fer vrijednosti. Međutim, uvažavanjem mogućnosti da naknada bude sasvim proizvoljno određena i različita od one koja bi se odredila u transakciji između nepovezanih strana spektar mogućnosti postaje još veći.

5. ZAKLJUČAK

Svrha ovog rada bila je istražiti postojeće stanje računovodstvenog okvira za poslovne kombinacije društava pod zajedničkom kontrolom na nacionalnoj i međunarodnoj razini. Kako je prikazano u radu, postojeći standardi financijskog izvještavanja daju vrlo malo uputa oko adekvatne primjene računovodstvenog modela na transakcije poslovnih kombinacija društava pod zajedničkom kontrolom. Dok neki standardi imaju bar neke upute (HSFI), neki (MSFI) nemaju nikakvih uputa za adekvatan tretman ovakvih transakcija. Štoviše, jedino jasno definiraju da se standard, koji općenito pokriva poslovne kombinacije, ne primjenjuje na posebnu vrstu poslovnih kombinacija - kombinacija društava pod zajedničkom kontrolom.

Nadalje, svrha je bila analizirati trenutačno stanje razvoja modela za poslovne kombinacije pod zajedničkom kontrolom. Kako je prikazano, određeni model postoji, ali daje značajan broj mogućih opcija i alternativa što sve ne doprinosi ostvarenju cilja financijskog izvještavanja, odnosno pružanja kvalitetnih i pouzdanih informacija korisnih širokom krugu korisnika. Pregledom postojećih istraživanja na ovom području razvidno je da je upravo razvoj jedinstvenog modela, odnosno standarda, nužan kako bi se osigurala harmonizacija računovodstvenog tretmana fenomena poslovnih kombinacija društava pod zajedničkom kontrolom na globalnoj razini.

Na temelju svega prethodno navedenoga, može se zaključiti da primjena predviđenih koncepata na način kako je prethodno navedeno, ostavlja mogućnost ostvarivanja različitih učinaka iste transakcije ovisno o izboru društva. Naime, prema Bellandiju (2021, str. 64) moguće je da društva iskoriste prilike za dobitak ili gubitak zbog izbora fer vrijednosti opravdavanjem korištenja fer u odnosu na knjigovodstvenu vrijednost. Isto tako, moguće je da ostvare koristi i proizvoljnim biranjem određene definicije knjigovodstvene vrijednosti.

Što se tiče ovih aspekata, projekt IASB-a još uvijek je na razini rasprave čime se ostavljaju daljnje mogućnosti brojim istraživačima da aktivno prate razvoj budućih rješenja oko kombinacija društava pod zajedničkom kontrolom, ne

isključujući mogućnost aktivnog predlaganja robusnijih rješenja. Dodatno, novije analize po promatranom pitanju trebalo bi horizontalno proširiti na razini zemalja EU-a u cilju sistematizacije nacionalnih rješenja u odnosu na zaključna IASB-ova razmatranja.

REFERENCE

1. Bellandi, F. (2021) Business Combinations under Common Control: The Gain/loss Group Perspective. What the IASB Project Leaves Unaddressed, *International Journal of Business and Management*; Vol. 16, No. 11; str. 59-75. Dostupno na: <https://doi.org/10.5539/ijbm.v16n11p59> [30. rujna 2023.]
2. Committee of European Securities Regulators (CESR) (2008). *Extract from EECS's database of enforcement decisions (08-283)*. Dostupno na: https://www.esma.europa.eu/sites/default/files/library/2015/11/08_283.pdf [15. listopada 2023.]
3. DIREKTIVA 2013/34/EU EUROPSKOG PARLAMENTA I VIJEĆA od 26. lipnja 2013. o godišnjim financijskim izvještajima, konsolidiranim financijskim izvještajima i povezanim izvješćima za određene vrste poduzeća, o izmjeni Direktive 2006/43/EZ Europskog parlamenta i Vijeća i o stavljanju izvan snage direktiva Vijeća 78/660/EEZ i 83/349/EEZ. Dostupno na: <https://eur-lex.europa.eu/legal-content/HR/TXT/HTML/?uri=CELEX:32013L0034> [12. listopada 2023.]
4. Direktiva Vijeća 2009/133/EZ od 19. listopada 2009. o zajedničkom sustavu oporezivanja koji se primjenjuje na spajanja, podjele, djelomične podjele, prijenos imovine i zamjene dionica društava iz različitih država članica te na prijenos sjedišta SE-a ili SCE-a iz jedne države članice u drugu. Dostupno na: <https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX:32009L0133> [12. listopada 2023.]
5. EFRAG (2011) *Accounting for business combinations under common control. Discussion paper*. Dostupno na: https://www.efrag.org/Assets/Download?assetUrl=%2Fsites%2Fwebpublishing%2FSiteAssets%2FBCUCC_DP.pdf [16. listopada 2023.]
6. EFRAG (2012) *Accounting for business combinations under common control. Feedback statement*. Dostupno na: <https://www.efrag.org/Assets/Download?assetUrl=%2Fsites%2Fwebpublishing%2FSiteAssets%2FFeedback%2520Statement%2520on%2520the%2520DP%2520%2527Accounting%2520for%2520Business%2520Combinations%2520under%2520Common%2520Control%2527.pdf> [16. listopada 2023.]
7. EFRAG (2021) *Feedback to respondents – EFRAG Final Comment Letter*. Dostupno na: <https://www.efrag.org/Assets/Download?assetUrl=%2Fsites%2Fwebpublishing%2FSiteAssets%2FFeedback%2520statement%2520on%2520BCUCC%2520CL.pdf> [16. listopada 2023.]
8. FASB *Statement of Financial Accounting Standards No. 141*. Dostupno na: <http://www.fasb.org> [10. travnja 2019.]
9. Fiume, R., Onesti, T., Romano, M. i Taliento, M. (2015) Dialogue with standard setters. Business Combinations under Common Control: Concerns, Criticisms and Strides, *Financial reporting*, FrancoAngeli Editore, Vol. 1, str. 107-126.

10. Hrvatski odbor za računovodstvo i računovodstvene standarde (1996) Međunarodni računovodstveni standardi. *Narodne novine* 65/96. Dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/1996_08_65_1276.html [19. rujna 2023.]
11. Hrvatski odbor za računovodstvo i računovodstvene standarde (2000) Odluka o objavljivanju promijenjenih Međunarodnih računovodstvenih standarda. *Narodne novine* 2/20. Dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/2000_01_2_17.html [19. rujna 2023.]
12. International Accounting Standard Board (IASB) (2004). *IFRS 3 Business combinations*. Dostupno na <https://www.iasb.org> [15. svibnja 2006.]
13. International Accounting Standard Board (IASB) (2011) *Business Combinations under Common Control, Discussion Paper DP/2020/2*. Dostupno na: <https://www.ifrs.org/content/dam/ifrs/project/business-combinations-under-common-control/discussion-paper-bcucc-november-2020.pdf> [20. listopada 2023.]
14. International Accounting Standard Board (IASB) (2011b) *Agenda Consultation*. Dostupno na: <https://www.ifrs.org/projects/completed-projects/2012/2011-agenda-consultation/#final-stage> [20. listopada 2023.]
15. International Accounting Standard Board (IASB) (2019) *Predecessor approach--carrying amounts*. Dostupno na: <https://www.ifrs.org/content/dam/ifrs/meetings/2019/october/iasb/ap23a-bcucc.pdf> [20. listopada 2023.]
16. International Accounting Standard Board (IASB) (2020) *Business Combinations under Common Control. Snapshot*, Dostupno na: <https://www.ifrs.org/content/dam/ifrs/project/business-combinationsunder-common-control/snapshot-dp-bcucc-november-2020.pdf> [20. listopada 2023.]
17. International Accounting Standard Board (IASB) (2023). *Who we are?*. Dostupno na <https://www.ifrs.org/about-us/who-we-are/#history> [30. listopada 2023.]
18. International Accounting Standard Board (IASB) (2023b) *Who uses IFRS Accounting Standards?*, Dostupno na: <https://www.ifrs.org/use-around-the-world/use-of-ifrs-standards-by-jurisdiction/#analysis-of-the-168-profiles> [30. listopada 2023.]
19. Janowicz, M. (2017) Business combinations under common control in International Financial Reporting Standards – is authoritative accounting guidance needed?, *Zeszyty Teoretyczne Rachunkowości*, Vol. 93, str. 97–111. Dostupno na: https://web.archive.org/web/20201125233805id_/https://ztr.skwp.pl/api/files/view/200713.pdf [20. listopada 2023.]
20. Nurnberg, H. i Sweeney, J. (2007). Understanding accounting for business combinations: An instructional resource. *Issues in Accounting Education*, Vol. 22, No. 2, str. 255–284. Dostupno na: <https://doi.org/10.2308/iace.2007.22.2.255> [3. listopada 2023.]
21. Polo-Garrido, F. i Meliá-Martí, E. (2021) Business combinations in cooperatives. A critical view of accounting standards, *Economic Research-Ekonomska Istraživanja*, Vol. 34, No. 1, str. 2522–2538. Dostupno na: <https://doi.org/10.1080/1331677X.2020.1833744> [5. listopada 2023.]
22. Zakon o porezu na dobit *Narodne novine* 177/04, 90/05, 57/06, 146/08, 80/10, 22/12, 148/13, 143/14, 50/16, 115/16, 106/18, 121/19, 32/20, 138/20, 114/22, 114/23. Dostupno na: <https://www.zakon.hr/z/99/Zakon-o-porezu-na-dobit> [19. rujna 2023.]

ACCOUNTING FOR BUSINESS COMBINATIONS OF ENTITIES UNDER COMMON CONTROL

Branka Remenarić, PhD

Zagreb School of Economics and Management

e-mail: bremenar@zsem.hr

Assistant Professor Ivan Čevizović, PhD

Čevizović Ivan j.t.d., Zagreb

e-mail: ivan.cevizovic@cevizovic.eu

Associate Professor Branimir Skoko, PhD

Faculty of Economics, University of Mostar

e-mail: branimir.skoko@ef.sum.ba

ABSTRACT

The business operations of companies as independent entities differ from those conducted within a group. Business activities within a group entail special challenges, particularly during group restructuring involving mergers and/or amalgamations of companies. Such transactions also pose challenges when independent companies are involved, i.e., companies that are not under the control of the same parent company. However, the challenge of appropriate accounting treatment becomes even greater when combinations within a group are involved. This is because changes in status within the group often occur without a takeover fee or with a fee that differs from the fair value. The question of the actual reasons for the change in status is equally challenging. The importance of such transactions is confirmed by the fact that work has been underway for several years to develop a suitable accounting standard that adequately covers this area. The purpose of this paper is to provide an overview of the current accounting framework and to research and present the ongoing activities aimed at creating a suitable international accounting framework.

Keywords: common control, acquisition, IFRS, business, combinations, taxes

JEL classification: F38, M41, M48, H21, H25



DIO 6: FINANCIJSKA PISMENOST I BIHEVIORALNE FINANCIJE

KOMPARATIVNA ANALIZA FINANCIJSKE PISMENOSTI UČENIKA SREDNJIH ŠKOLA U HRVATSKOJ, BOSNI I HERCEGOVINI I CRNOJ GORI

izv. prof. dr. sc. Tonči Svilokos

Sveučilište u Dubrovniku, Odjel za ekonomiju i poslovnu ekonomiju
e-mail: tonci.svilokos@unidu.hr

izv. prof. dr. sc. Iris Lončar

Sveučilište u Dubrovniku, Odjel za ekonomiju i poslovnu ekonomiju
e-mail: iris.loncar@unidu.hr

SAŽETAK

Financijska pismenost ključna je komponenta osobnog i ekonomskog uspjeha svakog pojedinca te igra značajnu ulogu u suvremenom društvu. Financijski pismeni pojedinci mogu bolje planirati svoju budućnost, što, osim njihova osobnog boljitka, implicira i stabilnost financijskog sustava i države kao cjeline. S obzirom na to da su mladi društvena skupina o kojoj ovisi budući razvoj, oni se stavljaju u fokus ovog istraživanja. Stoga su kao ciljevi ovog rada postavljeni: i) ispitivanje razina financijske pismenosti srednjoškolaca iz Hrvatske, Bosne i Hercegovine i Crne Gore, ii) identifikacija ključnih područja u kojima učenici pokazuju najlošije znanje, te iii) usporedba rezultata financijske pismenosti iz pojedinih područja financija između učenika koji dolaze iz svake pojedine zemlje. Rezultati istraživanja pokazuju da ne postoji statistički značajna razlika u razini financijske pismenosti među učenicima srednjih škola u Hrvatskoj, Bosni i Hercegovini i Crnoj Gori. Detektirana je jedino značajna razlika u poznavanju financija iz grupe pitanja koja se odnose na kamatnu stopu, gdje hrvatski ispitanici postižu nešto bolje rezultate u odnosu na ispitanike iz Bosne i Hercegovine, ali i Crne Gore.

Ključne riječi: *financijska pismenost, financijsko znanje, srednjoškolski učenici, komparativna analiza*

JEL klasifikacija: G53, D14

1. UVOD

Identificirani problem niske financijske pismenosti postao je globalni društveni izazov kojem na različite načine nastoje odgovoriti državna tijela i institucije, javna i privatna udruženja i organizacije, obrazovne institucije, kao i svi sustavi koji čine financijski sektor zemlje te su direktno ili indirektno involvirani u pružanje financijskih usluga. Međutim, potrebno je poći otpočetak ili, kako definira J. Stiglitz (2008), dobitnik Nobelove nagrade za ekonomiju: „Iza rasprava o budućoj politici stoji rasprava o povijesti – rasprava o uzrocima naše sadašnje situacije.“ Logično je, stoga, postaviti pitanje zašto baš danas problem financijske (ne)pismenosti izaziva toliku pozornost.

Inicijalni poticaj može se prepoznati u Svjetskoj financijskoj krizi 2007. godine, kojoj je u SAD-u prethodilo razdoblje relativno niskih kamatnih stopa. Građani SAD-a, dio koji nije bio kreditno sposoban, iskorištavali su povoljne uvjete niskih kamatnih stopa kupujući nekretnine zaduživanjem uz promjenjivu kamatnu stopu, premda nisu bili svjesni mogućih posljedica ovakvog zaduživanja. Banke su, s druge strane, koristile opisanu situaciju i odobravale hipotekarne kredite očekujući da će prodajom nekretnine lako namiriti svoja potraživanja. Međutim, usporavanje gospodarstva SAD-a uz rast kamatnih stopa imao je za posljedicu nemogućnost otplate kredita jednog dijela zajmoprimaca, dok je aktiviranje hipoteka predstavljalo udar na tržište nekretnina te su cijene počele strmoglavno padati uzrokujući gubitke u cjelokupnom bankarskom sektoru. Pojedinci su gotovo neočekivano bili suočeni s problemom insolventnosti te se sve intenzivnije počeo isticati problem njihove financijske (ne)pismenosti, koja je prepoznata kao jedan od temeljnih uzroka financijske krize. U svom kasnijem istraživanju, Lusardi *et al.* (2010) zaključuju da upravo izostanak financijske pismenosti dovodi do neodgovornog trošenja i neodrživog zaduživanja pojedinaca. Financijska kriza iz 2007. godine, mogli bismo reći, pandemijski se proširila na globalnu gospodarsku, društvenu i političku sferu.

Uspostavom mehanizama stabilizacije, kriza je na globalnoj razini obuzdana, međutim, to nije stišalo rasprave o financijskoj (ne)pismenosti. Sve veći broj znanstvenika i praktičara počeo se baviti istraživanjima ovog fenomena i čimbenika koji ga determiniraju. Naime, i danas, eksponencijalni rast financijske tehnologije i ponude složenih financijskih proizvoda suočavaju pojedince s problemom odabira optimalne opcije, tj. donošenja odluke koja neće imati negativne implikacije za njegovu budućnost, a bez posjedovanja osnovnih, odnosno sve više i naprednijih financijskih znanja, vrlo je teško očekivati ispravne odabire i, posljedično, njihove pozitivne ishode.

Financijska pismenost u fokusu je istraživanja i u ovom radu. Spoznajući da na financijsku pismenost, odnosno na njezine sastavnice: znanje, ponašanje i stavove, utječu osobne i individualno-psihološke karakteristike, kao i društvene odrednice ispitanika, zamišljeno je da se financijska pismenost istraži unutar skupina sličnih, a ipak međusobno različitih ispitanika. Stoga je odlučeno da se istraživanje provede na uzorku hrvatskih, bosansko-hercegovačkih i crnogorskih srednjoškolaca, a kako bi se učinila *cross-country* analiza te dijagnosticirale možebitne razlike u razini financijske pismenosti između istaknutih ciljnih skupina. Struktura srednjoškolaca u svima trima skupinama bila je podjednaka što se tiče prve dvije skupine čimbenika: osobnih i individualno-psiholoških karakteristika. No, razlike su se pojavile u relevantnim društvenim karakteristikama. Učenici su sa sličnog geografskog prostora, okarakterizirani sličnim povijesnim naslijeđem (sve tri države nastale su raspadom SFRJ-a), no s financijskog aspekta imaju različite polazne osnove. Hrvatski srednjoškolci danas žive u Europskoj uniji i koriste euro kao svoju valutu, bosansko-hercegovački učenici su izvan Europske unije i koriste konvertibilnu marku, dok crnogorski srednjoškolci žive izvan Europske unije i eurozone, ali koriste euro. Bilo je, stoga, interesantno istražiti imaju li ove različite društvene odrednice utjecaj na razinu financijskog znanja srednjoškolaca. Na sličan je način koncipirano i istraživanje Raijas (2021), koje je provedeno u obliku *cross-country* analize na uzorku nordijskih zemalja: Danske, Finske, Norveške i Švedske. Njegovi rezultati ukazali su na to da je u međunarodnim usporedbama financijska pismenost u odabranoj skupini zemalja podjednaka – prilično visoka, dok razlike postoje samo u nekim relativno manje utjecajnim odrednicama – primjerice, Finci i Norvežani pokazali su se opreznijima u financijskim odlukama od Danaca i Šveđana. Podjednaka situacija po pitanju financijske pismenosti i njezinih komponenti objašnjena je sličnim društvenim okvirom odabranih zemalja. Naime, riječ je o visoko razvijenim gospodarstvima u kojima postoji dobra organizacija društava, kao i visoka razina obrazovanja građana. Na opisani način pristupljeno je dijagnosticiranju financijske pismenosti mladih u odabranim, geografskim položajem susjednim zemljama: Hrvatskoj, Bosni i Hercegovini i Crnoj Gori.

Rad je strukturiran tako da je nakon uvoda, u kojem je opisan istraživački problem, u drugom poglavlju dan pregled glavnih aspekata financijske pismenosti prema relevantnim znanstvenim istraživanjima, odnosno teorijskim i empirijskim dostignućima u ovom području. Potom je opisan metodološki okvir kvantitativnog istraživanja koje obuhvaća provedbu anketnog istraživanja iz kojeg proizlaze rezultati iz kojih se polučuju zaključci koji su prezentirani u

posljednjem dijelu rada. Rad se zaključuje isticanjem ograničenja provedenog istraživanja i sugeriranjem mogućih budućih pravaca istraživanja.

2. PREGLED PRETHODNIH ISTRAŽIVANJA

Organizacija za ekonomsku suradnju i razvoj (OECD) uspostavila je općeprihvaćenu metodologiju za istraživanje financijske pismenosti prema kojoj od 2005. godine provodi periodična istraživanja. Kao nadogradnju ovome, OECD je također uspostavio Međunarodnu mrežu za financijsko obrazovanje (INFE), koja promiče važnost financijske pismenosti, organizira programe financijskog obrazovanja, provodi istraživanja te identificira i promiče primjere dobre prakse na međunarodnoj razini. Ističe se da je glavna svrha istraživanja prikupiti relevantne informacije o financijskoj pismenosti i osigurati osnovu za usporedbu zemalja. Posljednjim istraživanjem, provedenim tijekom 2023. godine, obuhvaćeno je 69.000 ispitanika u dobi od 18 do 79 godina u 39 zemalja svijeta te je upitnikom procijenjeno financijsko znanje, ponašanje i odnos prema novcu ispitanika (OECD, 2023). Razvidno je da se financijska pismenost promatra kao složeni koncept koji prema definiciji OECD/INFE (2011) uključuje znanja, svijest, vještinu, stavove i ponašanje koji su nužni za donošenje ispravnih financijskih odluka i ostvarivanje financijskog blagostanja pojedinaca.

Financijska pismenost od krucijalne je važnosti u procesima donošenja odluka na individualnoj i društvenoj razini (Hastings *et al.*, 2013). Na individualnoj razini ona utječe na ponašanje pojedinaca u odnosu na potrošnju, formiranje štednje, donošenje odluka o ulaganjima, osiguravanju mirovinskih primanja u budućnosti i sl. (Henager i Cude, 2016), dok viša razina financijske pismenosti na društvenoj razini utječe na akumulaciju bogatstva i intenzivniju involviranost na financijskim tržištima. Premda pojedinci donose svoje financijske odluke racionalno, potaknuti ekonomskim motivima koji su promjenjive prirode, ne smije se zanemariti socijalna komponenta, tj. intrinzična motiviranost s obzirom na to koje se odluke pojedinaca razlikuju s obzirom na njihove specifične sposobnosti i iskustva, a koja također predstavljaju varijabilni čimbenik. Socionormativni i demografski čimbenici neupitno utječu na efikasno procesuiranje relevantnih informacija i donošenje financijskih odluka, a na njih edukacija nema ili ima infinitezimalni utjecaj. Financijske edukacije, u pravilu, kombiniraju strategije kojima se nastoje aktivirati i ekstrinzična i intrinzična motivacija. Ekstrinzična motivacija potaknuta je vanjskom „silom“, tj. postizanjem cilja radi vanjske nagrade – primjerice, podizanje razine financijske

pismenosti radi potencijalne zarade ili rješavanja problema prezaduženosti. Intrinzična motivacija nastaje kao rezultat potrebe pojedinaca za autonomijom i kompetentnošću, odnosno željom da se što bolje inkorporiraju u svoje okruženje – primjerice, upoznavanje karakteristika novog financijskog proizvoda radi užitka u stjecanju novog znanja i postizanja zadovoljstva, odnosno prestižne pozicije na temelju toga.

Financijska pismenost raspoznaje se kao bitna komponenta u makroekonomskim modelima. Primjerice, Burke i Manz (2011) ispitivali su povezanost razine financijske pismenosti pojedinaca s njihovim procjenama inflatornih očekivanja i dokazali da su financijski pismeniji pojedinci sposobniji prepoznati relevantne informacije. Njihov je zaključak bio da iz razlike u financijskoj, odnosno općenito ekonomskoj pismenosti proizlazi većina demografskih varijacija koje se odnose na inflatorna očekivanja.

Pitanje važnosti financijske pismenosti posebno se potencira u situacijama neočekivanih poremećaja, kada na vidjelo izlaze problemi suočavanja s izvanrednim troškovima. Dokaz tome je i situacija pandemije bolesti COVID-19, kada su zbog financijske nepismenosti i nespremnosti brojni pojedinci iskazivali neotpornost da u duljem razdoblju podnesu izostanak uobičajenih primanja (Demertzis, Domínguez-Jiménez i Lusardi, 2020).

Sve aspekte financijske pismenosti vrlo je teško propitati jednim upitnikom. Naime, upitnik bi, s obzirom na velik broj dijelova ovog složenog konstrukta, bio preopsežan i samim time neprihvatljiv. Stoga se autori najčešće odlučuju za parcijalne analize u kojima ispitanicima postavljaju pitanja povezana samo s odabranom komponentom financijske pismenosti. Okosnicu većine upitnika kojima se istražuje financijsko znanje čine tri temeljna pitanja koja su osmislile začetnice istraživanja financijske pismenosti – Lusardi i Michell (2011). Riječ je o pitanjima kojima se propituje razumijevanje triju osnovnih financijskih koncepata: izračun kamata, procjena učinaka inflacije i diversifikacija rizika. Pitanja su prikazana na Slici 1.

Slika 1. Temeljna pitanja o financijskom znanju

„Big Three“ – upitnik za procjenu financijske pismenosti

- 1) Pretpostavite da ste uložili \$100 na štedni račun i da je godišnja kamatna stopa 2 %. Kojim ćete iznosom raspolagati nakon pet godina, ako u međuvremenu niste podizali novac?

Većim od \$102*.

Točno sa \$102.

Nižim od \$102.

Ne znam.

Ne želim odgovoriti.

- 2) Pretpostavite da je godišnja kamatna stopa na štednju 1 %, a da je godišnja stopa inflacije 2 %. Koliku ćete vrijednost robe moći kupiti novcem kojim ćete raspolagati na računu nakon godine dana?

Veću vrijednost nego na početku.

Jednaku vrijednost.

Manju vrijednost nego na početku*.

Ne znam.

Ne želim odgovoriti.

- 3) Odredite je li izjava točna ili netočna. „Kupnjom dionica jedne korporacije osigurava se sigurniji povrat nego ulaganjem u investicijski fond.“

Točno.

Netočno*.

Ne znam.

Ne želim odgovoriti.

Napomena: * Točni odgovori su podebljani.

Izvor: Lusardi, A. i Mitchell, O. S. (2011). Financial literacy and retirement planning in the United States. *Journal of Pension Economics & Finance*, Vol. 10, No. 4, str. 509-525.

Prva dva pitanja zahtijevaju i osnovne matematičke/računske vještine, dok je treće pitanje povezano s poznavanjem osnovnog financijskog kategorijalnog sustava. Autorice su se pri oblikovanju pitanja rukovodile sljedećim načelima: jednostavnošću, relevantnošću, kratkoćom i sposobnošću razlikovanja (Lusardi i Michell, 2023). Pitanja su koncipirana tako da mjere temeljna znanja bitna za donošenje svakodnevnih financijskih odluka te su dovoljno općenita da se

izbjegne problem različitog okruženja u kojem se istraživanje provodi. Povrh toga, upitnik je trebao omogućiti da se malim brojem pitanja omogući diferenciranje ispitanika u smislu njihove različite razine financijskog znanja.

I same su autorice Lusardi i Michell istraživanjima koja su uslijedila proširivale ova tri temeljna pitanja, a jedan od posljednjih upitnika, kojim se 2020. godine na globalnoj razini istražio stupanj financijske pismenosti, sastojao se od pet pitanja. U Tablici 1. prikazana je razina financijske pismenosti utvrđena upravo ovim upitnikom u Europi. Prezentirani podaci prikazuju udio odraslih osoba koje su točno odgovorile na najmanje tri od pet postavljenih pitanja, a što je u radu definirano kao prag za ostvarivanje financijske pismenosti.

Tablica 1. Razina financijske pismenosti u Europi 2020. godine

DRŽAVA	RAZINA FINANCIJSKE PISMENOSTI (%)	DRŽAVA	RAZINA FINANCIJSKE PISMENOSTI (%)
Albanija	14	Luksemburg	53
Andora	n/a	Mađarska	54
Austrija	53	Makedonija	21
Belgija	55	Malta	44
Bjelorusija	38	Moldavija	27
Bosna i Hercegovina	27	Monako	n/a
Bugarska	35	Nizozemska	66
Crna Gora	48	Norveška	71
Češka	58	Njemačka	66
Danska	71	Poljska	42
Estonija	54	Portugal	26
Europski dio Rusije	38*	Rumunjska	22
Finska	63	San Marino	n/a
Francuska	52	Slovačka	48
Grčka	45	Slovenija	44
Hrvatska	44	Srbija	38
Irska	55	Španjolska	49
Island	n/a	Švedska	71
Italija	37	Švicarska	57
Kosovo	20	Ujedinjeno Kraljevstvo	67
Latvija	48	Ukrajina	40
Lihtenštajn	n/a	Vatikan	n/a
Litva	39		

Napomena: * podatak se odnosi na Rusiju, a ne samo na njezin europski dio

Izvor: obrada autora prema Klapper, L. i Lusardi, A. (2020.): Financial literacy and financial resilience: Evidence from around the world. *Financial Management*, Vol. 49, No. 3, str. 589-614

Međutim, spoznavanje razine financijske pismenosti nije samo po sebi cilj. Prepoznata problematična financijska pitanja (područja), kao i prepoznate skupine ispitanika s niskom financijskom pismenošću smjernica su kreatorima nacionalnih obrazovnih politika za razvoj kurikuluma osobnih financija. Na razini Europske unije evidentne su aktivnosti kojima se nastoji potaknuti razvoj programa financijskog opismenjavanja. Tako, primjerice, Europska komisija i međunarodne organizacije provode i sufinanciranje programe za razvoj financijske pismenosti i financijskog obrazovanja u državama članicama.

No, obuhvat djelovanja programa za unapređenje financijske pismenosti nužno se razlikuje s obzirom na razinu razvijenosti zemalja. U visoko razvijenim zemljama financijska pismenost javlja se kao svojevrsna nadogradnja zaštite potrošača, a kao ciljevi financijske edukacije postavljaju se osposobljavanje pojedinaca za upotrebu sofisticiranih financijskih proizvoda te za donošenje bitnih financijskih odluka povezanih s kapitaliziranjem sredstava u cilju ostvarivanja prava na mirovinu. S druge strane, u nerazvijenijim gospodarstvima financijsko opismenjavanje uglavnom se ograničava na povećavanje dostupnosti i prepoznatljivosti raznovrsnih financijskih proizvoda i usluga širem krugu korisnika. Nužnost dijametralno suprotnog pristupa u razvijenim i nerazvijenim područjima najbolje se može prikazati činjenicom da, prema rezultatima izvještaja FinScope, u Africi samo 21 % odraslih osoba ima otvoren račun na banci, dok se u ulozi korisnika bankarskih kredita nalazi svega 4 % stanovnika ovog kontinenta (Chamboko i Mutsonziwa, 2019). Dakle, razvidna je potreba da financijsko opismenjavanje u ovom dijelu svijeta bude usmjereno prema financijskoj inkluziji pojedinaca i njihovu upoznavanju s postojećim proizvodima i uslugama.

Sukladno svemu istaknutom, u nastavku će se ispitati razina financijske pismenosti učenika srednjih škola koji dolaze iz Hrvatske, Bosne i Hercegovine i Crne Gore (kao cjeline), utvrditi ključna područja u kojima su učenici najslabiji te napraviti usporedba rezultata financijske pismenosti iz pojedinih područja financija između učenika koji dolaze iz svake pojedine zemlje.

Posljednjih desetak godina u Hrvatskoj su provedena brojna istraživanja koja analiziraju financijsku pismenost mladih (Vehovec, Rajh i Škreblin Kirbiš, 2015; Lončar, Golemac i Arapović, 2017; Šubić *et al.*, 2019 itd.) te su se njima analizirale ne samo razina financijske pismenosti nego i utjecajni čimbenici, posljedice (ne)pismenosti i korelacije između određenih ekonomskih i društvenih pojavnosti i razine financijske pismenosti. Za razliku od toga, u Bosni i Hercegovini takva su istraživanja prilično rijetka. Jedno interesantnije pred-

stavljeno je u radu autora Halilović *et al.* (2019). Uzorak u ovom radu uključivao je 582 ispitanika u dobi od 18 do 79 godina te je analizom dobivenih odgovora zaključeno da je prosječna razina financijskog znanja osoba mlađih od 30 godina 4,8, što je niže od minimalnih pet (OECD/INFE definira pet kao granicu između pismenosti i nepismenosti). Posebno je zabrinjavajuća činjenica da je samo 64,4 % ispitanika odabralo točan odgovor na pitanje o jednostavnom obračunu kamata, a tek 47,4 % ih je točno odgovorilo na pitanje o složenim kamatnim stopama. Za Crnu Goru, prema našim spoznajama, ne postoje znanstvena istraživanja ovog problema. No, neosporno je da je u posljednje vrijeme došlo do njegova prepoznavanja. Tako je 2022. godine Nacionalno povjerenstvo za razvoj financijskog obrazovanja Crne Gore, uz podršku stručnjaka OECD-a, usvojilo Program razvoja financijskog obrazovanja u Crnoj Gori 2023. – 2027. godine (CBCG 2022).

3. METODOLOGIJA, PODACI I VARIJABLE

Ovo istraživanje temelji se na podacima prikupljenim anketiranjem učenika srednjih škola u razdoblju od 1. ožujka do 30. travnja 2023. Naime, istraživači Odjela za ekonomiju i poslovnu ekonomiju Sveučilišta u Dubrovniku organizirali su radionice financijske pismenosti na kojima su sudjelovali srednjoškolci iz Hrvatske (područje Dubrovačko-neretvanske i Splitsko-dalmatinske županije), Bosne i Hercegovine (područje Zapadno-hercegovačkog kantona i Hercegovačko-neretvanskog kantona) i Crne Gore (područje općine Budva, općine Herceg-Novi i općine Kotor). Ukupno je prikupljeno 590 odgovora, od čega 59,3 % iz Hrvatske, 23,4 % iz Bosne i Hercegovine i 17,3 % iz Crne Gore.

Anketni upitnik koji su ispunjavali učenici sastoji se od dvaju dijelova. Prvi dio sadrži deset, a drugi dio dvanaest pitanja. U prvom dijelu postavljana su pitanja kojima se utvrđivao profil ispitanika (dob, spol itd.), a u drugom dijelu postavljana su pitanja kojima se utvrđivala razina njihove financijske pismenosti. Polazi se od pretpostavke da se financijska pismenost može u dobroj mjeri izjednačiti s financijskim znanjem srednjoškolaca. Naime, istraživanje svih komponenti financijske pismenosti zahtijevalo bi angažman značajnih resursa, a, prije svega, spremnost odvajanja značajnog vremena od strane ispitanika. Stoga se, s ciljem smanjenja kompleksnosti istraživanja, pristupilo istraživanju samo jedne komponente. Ovo je i teorijski bila prihvatljiva pretpostavka jer je sama životna dob ispitanika izravno utjecala na kratkoću vremena unutar kojeg su oni mogli formirati svoje vještine i ponašanja. Povrh toga, činjenica je da

stavovi, kao poticaj za ponašanje o kojem ovise aktivnosti i odluke, u pravilu, imaju veću postojanost kada su formirani u izravnom iskustvu nego neizravno, pa kako je u slučaju srednjoškolaca izravno iskustvo relativno ograničenog karaktera, pokazalo se prihvatljivim isključiti iz analize dio koji se odnosi na stavove.

Pitanja iz drugog dijela nudila su četiri moguća odgovora od kojih je jedan bio „ne znam“. Ispitanicima je naglašeno da izaberu odgovor za koji su sigurni da je točan, a u suprotnom da izaberu odgovor „ne znam“ kako bi se mogućnost slučajnog odabira točnog odgovora u slučaju kada nisu znali pravi odgovor svela na najmanju moguću mjeru. Smatrajući da su učenici već upoznati s pitanjima koja se uobičajeno postavljaju u istraživanjima financijske pismenosti, formirana je skupina pitanja koja pokrivaju referentna područja te su time usporediva s pitanjima postavljenim u sličnim studijama (OECD, 2023; Lusardi *et al.*, 2010), ali su ipak bila dovoljno drugačija da učenici ne bi unaprijed znali odgovor na njih. Vrijeme potrebno za ispunjavanje drugog dijela upitnika ograničeno je na 20 minuta.

U ovom radu korišteni su Pearsonov hi-kvadrat test, test omjera vjerojatnosti (engl. *likelihood ratio*) i Cramerov V test za utvrđivanje povezanosti i snage veze između kategoričkih varijabli, te t-testovi za usporedbu srednjih vrijednosti. Svi izračuni i grafikoni napravljeni su u SPSS-u (ver. 21).

Pearsonov hi-kvadrat test koristi se kako bi se utvrdilo postojanje značajne statističke povezanosti između dviju kategoričkih varijabli. Obično se koristi za analizu podataka u obliku kontingencijske tablice (engl. *contingency table*), koja unakrsno prikazuje dvije kategoričke varijable, pokazujući učestalost svake kombinacije kategorija (Wooldridge, 2015). Nulta hipoteza (H_0) je: nema povezanosti između dviju kategoričkih varijabli, a alternativna hipoteza (H_1) je: postoji povezanost između dviju kategoričkih varijabli.

Hi-kvadrat test (X^2) izračunava se na temelju opažene (O_{ij}) i očekivane (E_{ij}) frekvencije u tablici koristeći formule (1) i (2):

$$E_{i,j} = \frac{\text{Zbroj } i\text{-tog retka} \cdot \text{Zbroj } j\text{-tog stupca}}{\text{Sveukupan zbroj}} \quad (1)$$

$$X^2 = \sum \frac{(O_{ij} - E_{ij})^2}{E_{ij}} \quad (2)$$

Alternativa Pearsonovu hi-kvadrat testu jest test omjera vjerojatnosti (engl. *likelihood ratio*) koji se bazira na *maximum-likelihood* teoriji. Kao i kod Pearso-

nova hi-kvadrat testa, tako se i kod ovog testa uspoređuju opažene i očekivane frekvencije.

$$L_{X^2} = 2 \sum O_{i,j} \ln \left(\frac{O_{i,j}}{E_{i,j}} \right) \quad (3)$$

Cramerov V koristi se za procjenu jačine veze između dviju nominalnih ili ordinalnih varijabli u kontingencijskoj tablici. Vrijednost Cramerova V koeficijenta varira između 0 (potpuna neovisnost) do 1 (potpuna veza). Veće vrijednosti ukazuju na jaču povezanost između dviju varijabli (Field, 2013).

Pored navedenog, u radu se primjenjuje i t-test. T-test koristi se za usporedbu srednjih vrijednosti dviju skupina kako bi se ustanovilo postoji li značajna razlika između njih. Postoje dvije glavne vrste t-testova: t-test neovisnih uzoraka (engl. *Independent samples t-test*) i t-test uparenih uzoraka (engl. *Paired samples t-test*) (Greene, 2000).

U t-testu neovisnih uzoraka pretpostavlja se da imamo dvije neovisne skupine, Grupi 1 i Grupi 2, i želi se usporediti njihove srednje vrijednosti. Ovim testom provjeravali smo postoji li značajna razlika u financijskoj pismenosti između učenika iz Hrvatske, Bosne i Hercegovine i Crne Gore. Nulta hipoteza (H_0) je: Srednje vrijednosti Grupe 1 i Grupe 2 su jednake ($\mu_1 = \mu_2$), a alternativna hipoteza (H_1) je: Srednje vrijednosti Grupe 1 i Grupe 2 nisu jednake ($\mu_1 \neq \mu_2$). S pomoću formule (3) uspoređujemo srednje rezultate financijske pismenosti (varijable INT_RATE, LOAN i INVEST – vidi Tablicu 2.):

$$t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\left(\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2} \right)}} \quad (4)$$

gdje su:

- $\bar{x}_1$ i $\bar{x}_2$ srednje vrijednosti uzorka Grupe 1 i Grupe 2
- s_1^2 i s_2^2 varijance uzorka Grupe 1, odnosno Grupe 2 i
- n_1 i n_2 veličine uzorka Grupe 1 i Grupe 2.

U t-testu ovisnih uzoraka pretpostavlja se da imamo jednu skupinu sudionika ili subjekata i želi se usporediti njihova svojstva pod dvama različitim uvjetima. Nulta hipoteza (H_0) je: Prosječna razlika između uparenih opažanja je nula ($\mu_d = 0$), a alternativna hipoteza (H_1) je: Srednja razlika između uparenih opažanja nije nula ($\mu_d \neq 0$). Ovaj pristup koristimo za izračun mogućih razlika između varijabli (INT_RATE, LOAN i INVEST). T-test uparenih uzoraka izračunava t-vrijednosti na temelju razlika između uparenih opažanja:

$$t = \frac{\bar{x} - \mu}{\frac{\sigma}{\sqrt{n}}} \quad (5)$$

gdje su:

- $\bar{x}$ srednja vrijednost uzorka
- μ pretpostavljena srednja vrijednost
- σ standardna devijacija
- n broj opservacija.

Karakteristike koje bi mogle utjecati na financijsku pismenost su spol, država iz koje su ispitanici, škola koju pohađaju, razred koji pohađaju, prethodno radno iskustvo za koje je dobivena određena svota novca, glavni izvor džeparca ispitanika i glavni način stjecanja financijskih znanja. Također nam je bilo zanimljivo utvrditi koliko dobro ispitanici procjenjuju svoje financijsko znanje u odnosu na stvarno postignuti rezultat.

Druga skupina pitanja iz upitnika koja se koristi za procjenu financijskog znanja sadrži dvanaest pitanja iz kojih su izračunate sljedeće varijable: SCORE (ukupan broj bodova postignut na svim pitanjima), SCORE_BIN (generiran razvrstavanjem rezultata financijske pismenosti u tri kategorije), INT_RATE, LOAN i INVEST. Način na koji je napravljeno grupiranje za izračun navedenih triju varijabli pokazan je u Tablici 2.

Tablica 2. Varijable kojima se mjeri razina financijske pismenosti

	Pitanje/Opis	Varijabla
1.	Kamata je: (1 bod)	INT_RATE
2.	Kućni budžet je: (1 bod)	LOAN
3.	Obračun kamate na početnu glavnice i pripisanu kamatu naziva se: (2 boda)	INT_RATE
4.	Ako je godišnja stopa inflacije 2 %, a kamata na oročeni depozit 4 %, tada je realna kamatna stopa: (2 boda)	INT_RATE
5.	Porast realne kamatne stope potiče ljude na: (2 boda)	INT_RATE
6.	Koja je od sljedećih tvrdnji o obveznicama netočna: (2 boda)	INVEST
7.	Stambeni krediti ne mogu se povezati s: (2 boda)	LOAN
8.	Kamatna stopa koja se obračunava u razdoblju od korištenja kredita do trenutka početka otplate naziva se: (2 boda)	LOAN
9.	Kako bi se smanjio rizik ulaganja, investitorima se savjetuje: (2 boda)	INVEST
10.	Izračun ukupne kamate, dekurzivni obračun kamata, godišnji, jednostavni (3 boda)	INVEST
11.	Izračun buduće glavnice, dekurzivni, mjesečni, složeni obračun kamata (3 boda)	INVEST
12.	Korištenje tečajne liste (3 boda)	LOAN

13.	Izračunata varijabla na temelju ukupnih rezultata	SCORE
14.	Kategorijalna varijabla generirana na temelju varijable SCORE	SCORE_BIN

Napomena: Za svako pitanje ponuđena su četiri moguća odgovora (od kojih je jedan odgovor točan). Uz to je dana mogućnost odabira odgovora „ne znam“. Kompletan anketni upitnik koji se koristio u ovom istraživanju i koji sadrži sve ponuđene odgovore te cjelokupan tekst zadataka za izračun može se dobiti na zahtjev.

Izvor: izračun autora

Ispitanici su mogli ostvariti ukupno 25 bodova na temelju dvanaest pitanja o financijskoj pismenosti. Prva dva pitanja nosila su po jedan bod, sedam pitanja po dva boda, a zadnja tri pitanja po tri boda. Odgovori su grupirani u tri kategorije: nizak rezultat – za ispitanike koji su odgovorili s manje od 50 % uspješnosti, srednji rezultat za one koji su postigli rezultat od 50 % do 75 % točnosti i visok rezultat za one koji su postigli iznad 75 % točnost odgovora (varijabla SCORE_BIN).

4. REZULTATI I DISKUSIJA

Kako bismo dobili preglednost i uvid za bolje razumijevanje i interpretaciju, napravili smo deskriptivnu analizu pitanja koja smo postavili za utvrđivanje profila ispitanika. Rezultati su dani u Tablici 3. Ujedno su u tablici naznačeni nazivi varijabli koje se koriste u nastavku.

Podaci u Tablici 3. pokazuju da je većina ispitanika koji su sudjelovali u anketi iz Hrvatske. Žena je nešto više nego muškaraca, a ispitanici su uglavnom rođeni 2004. godine i pohađaju četvrti razred srednje škole. Gotovo podjednako ih je iz gimnazije i četverogodišnjih strukovnih škola, a samo 16 ispitanika pohađa trogodišnju strukovnu školu.

Tablica 3. Deskriptivna statistika eksplanatornih varijabli

Opis – Varijabla	Frekv.	%	Opis – Varijabla	Frekv.	%
<i>Zemlja podrijetla – COUNTRY</i>			<i>Jeste li ikada radili neki posao za koji ste primali novčanu naknadu? – WORK</i>		
Bosna i Hercegovina	138	23,4	Da	496	84,1
Crna Gora	102	17,3	Ne	94	15,9
Hrvatska	350	59,3	<i>Koji je Vaš glavni izvor novca (džeparca)? – PM</i>		
<i>Spol – GENDER</i>			Od roditelja za obavljanje kućanskih poslova	52	8,8
Ženski	316	53,6	Od roditelja bez obavljanja kućanskih poslova	128	21,7
Muški	274	46,4	Novčani darovi od rodbine i/ili prijatelja	56	9,5
<i>Godina rođenja – Y_BIRTH</i>			Ostalo	58	9,8
2003. godine	22	3,7	Rad u obiteljskoj tvrtki	70	11,9
2004. godine	298	50,5	Rad za vrijeme školskih praznika	226	38,3
2005. godine	200	33,9	<i>Koji je glavni izvor odakle ste stekli financijsko znanje? – FK</i>		
2006. godine	58	9,8	Internet	138	23,4
2007. godine	12	2,0	Ostali mediji (TV, novine, radio)	24	4,1
<i>Srednja škola – HS</i>			Ostalo	52	8,8
Gimnazija	290	49,2	Prijatelj	8	1,4
Četverogodišnja strukovna škola	284	48,1	Roditelji	276	46,8
Trogodišnja strukovna škola	16	2,7	Škola	92	15,6
<i>Razred – GRADE</i>			<i>Procijenite razinu vlastitog financijskog znanja – FK_EST</i>		
1. razred	10	1,7	1 (vrlo nisko)	40	6,8
2. razred	32	5,4	2 (nisko)	84	14,2
3. razred	196	33,2	3 (prosječno)	268	45,4
4. razred	352	59,7	4 (visoko)	152	25,8
			5 (vrlo visoko)	46	7,8


Izvor: izračun autora

Gotovo svi ispitanici imali su iskustvo plaćenog posla, a njih 38 % navelo je da im je glavni izvor džeparca rad za vrijeme školskih praznika. Financijsko znanje uglavnom stječu od roditelja i ocjenjuju ga prosječnom ocjenom.

Nažalost, gledajući ukupne rezultate (vidi Grafikon 1.), čini se da je njihovo stvarno financijsko znanje na nižoj razini od one kako su je sami procijenili, ali i od nacionalnog prosjeka (vidi Tablicu 1.). Može se zaključiti da je financijska pismenost ispitanika niska ili vrlo niska. Samo je 16 ispitanika od ukupnog

broja, odnosno 2,7 %, odgovorilo na dvanaest pitanja drugog dijela upitnika s 90 % ili višom točnošću. Podaci o postignutim rezultatima po zemljama prikazani su na Grafikonu 1.

Grafikon 1. Financijska pismenost po zemljama



Izvor: izračun autora

Pitanje s najviše netočnih odgovora bilo je pitanje broj 12, koje je zahtijevalo primjenu priložene tečajne liste i odgovor koliko se eura može dobiti u poslovnoj banci za sto australskih dolara. Na to pitanje točno je odgovorilo samo 15,9 % ispitanika. Razlog tome za hrvatske ispitanike može biti nedavno uvođenje eura i promjene u načinu iskazivanja tečajnih lista banaka, a za ostale ispitanike eventualna razlika u tečajnim listama koje objavljuju banke iz njihovih zemalja i tečajne liste koja im je priložena uz anketni upitnik.

Najviše točnih odgovora dano je na pitanje broj 5 (vidi Tablicu 2.), gdje ispitanici (s 80,3 % točnosti) prepoznaju da rast realne kamatne stope potiče ljude da više štede i manje se zadužuju, iako je samo njih 33,9 % točno izračunao realnu kamatnu stopu s obzirom na zadanu nominalnu kamatnu stopu i stopu inflacije (pitanje broj 4).

Ako je vrijednost Pearsonova hi-kvadrat testa značajnosti dovoljno mala (uobičajeno signifikantnost treba biti manja od 0,05), tada odbacujemo hipotezu da su varijable neovisne, odnosno podupire se teza da su na neki način one povezane (Field, 2013). Rezultati hi-kvadrat testova dani su u Tablici 4.

Tablica 4. Rezultati hi-kvadrat testova

	Vrijednost	df	Asimpt. znač. (dvostrana)	Vrijednost	df	Asimpt. znač. (dvostrana)
Povezanost varijable GENDER i varijable SCORE_BIN				Povezanost varijable WORK i varijable SCORE_BIN		
Pearson Chi-Square	17,105	2	0,000	10,712	2	0,020
Likelihood Ratio	17,637	2	0,000	13,728	2	0,011
Cramer's V	0,170		0,000	0,135		0,020
Povezanost varijable COUNTRY i varijable SCORE_BIN				Povezanost varijable HS i varijable SCORE_BIN		
Pearson Chi-Square	3,478	4	0,481	15,254	4	0,004
Likelihood Ratio	3,515	4	0,476	19,704	4	0,001
Cramer's V	0,054		0,481	0,114		0,004
Povezanost varijable GRADE i varijable SCORE_BIN*				Povezanost varijable PM i varijable SCORE_BIN		
Pearson Chi-Square	10,417	6	0,107	13,551	10	0,194
Likelihood Ratio	11,027	6	0,090	15,921	10	0,102
Cramer's V	0,014		0,107	0,107		0,194
Povezanost varijable Y_BIRTH i varijable SCORE_BIN*				Povezanost varijable FK_EST i varijable SCORE_BIN		
Pearson Chi-Square	8,491	8	0,387	38,326	8	0,000
Likelihood Ratio	6,902	8	0,547	37,246	8	0,000
Cramer's V	0,085		0,387	0,180		0,000
Povezanost varijable FK i varijable SCORE_BIN*				Napomena: Rezultate hi-kvadrat testova označenih sa * treba uzeti s rezervom jer je očekivani broj pojedinih kategorija manji od 5, međutim, mogu biti indikativni.		
Pearson Chi-Square	23,870	10	0,008			
Likelihood Ratio	23,229	10	0,010			
Cramer's V	0,142		0,008			

Izvor: izračun autora

Rezultati hi-kvadrat testova ukazuju na to da postoji veza između ostvarenog rezultata ispita financijske pismenosti i: spola ispitanika (GENDER), vrste srednje škole (HS), postojanja radnog iskustva za koji je primljena novčana naknada (WORK), vrste izvora stečenog financijskog znanja (FK) i vlastite procjene razine financijskog znanja (FK_EST). Nadalje, nije pronađena povezanost ostvarenog rezultata s obzirom na državu iz koje ispitanik dolazi (COUNTRY), razred koji pohađa (GRADE), godinu rođenja (Y_BIRTH) i glavni izvor novca (džeparca) (PM). Ovdje treba napomenuti da rezultate pojedinih hi-kvadrat testova treba uzeti s rezervom jer je očekivani broj pojedinih kategorija manji od 5, međutim, oni mogu biti indikativni.

Analiza podataka pokazala je da je preko 35 % muškaraca imalo srednji ili visok rezultat u drugom dijelu anketnog upitnika kojim se ispitala njihova

financijska pismenost, a žena s takvim rezultatom bilo je samo 23,4 %, što je u skladu sa zaključcima istraživanja koja su proveli Tinghog *et al.* (2021) te Bottazzi i Lusardi (2021), a koja također ukazuju na viši stupanj financijske pismenosti muškaraca. Nešto bolji rezultat od prosjeka imali su učenici četverogodišnjih strukovnih škola, a značajno lošiji od prosjeka učenici trogodišnjih strukovnih škola. Pokazalo se da su oni koji su već imali neko radno iskustvo ostvarili za 6 postotnih bodova bolji rezultat od onih koji to iskustvo nisu imali. Očekivano, oni koji su svoje znanje procijenili kao vrlo visoko ostvarili su i najbolje rezultate, međutim, velik je postotak (njih 67 %) onih koji su svoje znanje ocijenili iznadprosječnom ocjenom, a ostvarili su ispodprosječan rezultat, što se može komparirati sa sličnim rezultatima dobivenim u istraživanju Allgood i Walsta (2016) te Balasubramnian i Sargent (2020), koja su pokazala da ljudi često precjenjuju svoju pismenost.

Primijenjen je t-test kako bi se ispitalo postoji li značajna razlika u razini financijske pismenosti za različite vrste financijskog znanja. Naime, dvanaest pitanja o financijskom znanju grupirana su u tri varijable kako je pokazano u Tablici 2. Varijable INT_RATE, LOAN i INVEST sadrže ostvaren rezultat u pojedinoj skupini pitanja izražen u postotku. Prosječne vrijednosti, standardna devijacija te rezultati t-testa po parovima prikazani su u sljedećoj tablici.

Tablica 5. Usporedba prosječnih vrijednosti uparenih varijabli

Variable			Prosjek	Stand. devij.	Stand greš. prosjek
INT_RATE			0,4828	0,23596	0,00971
LOAN			0,3068	0,24346	0,01002
INVEST			0,4366	0,28657	0,01180
			Par 1	Par 2	Par 3
			INT_RATE - LOAN	INT_RATE - INVEST	LOAN - INVEST
Uparene razlike	Prosjek		0,17603	0,04620	-0,12983
	Stand. devij.		0,27657	0,32822	0,31591
	Stand. greš. prosjek		0,01139	0,01351	0,01301
	95 % Interval pouzdanosti	Donja	0,15367	0,01966	-0,15537
		Gornja	0,19839	0,07274	-0,10429
t			15,460	3,419	-9,982
df			589	589	589
Sig. (dvostrana)			0,000	0,001	0,000

Izvor: izračun autora

Ispitanici su, uzimajući ih kao jednu homogenu skupinu, pokazali najbolje znanje iz područja kamatnih stopa (48,28 %), a najlošije iz područja zajmova (30,68 %). Međutim, prosječan rezultat svih ispitanika u svim područjima manji je od 50 % i iznosi skromnih 40,80 %. Izračun je pokazao da je navedena razlika između pojedinih područja financijske pismenosti statistički značajna. Ovi rezultati mogu se koristiti pri definiranju programa za unapređenje financijske pismenosti.

Spearmanovim hi-kvadrat testom utvrdili smo da ne postoji povezanost kategoričkih varijabli SCORE_BIN i COUNTRY, a na temelju čega se zaključilo da ne postoji bitna razlika u financijskoj pismenosti između sudionika istraživanja iz različitih zemalja. Međutim, postavlja se pitanje postoji li značajna razlika u financijskoj pismenosti po pojedinim područjima financija između sudionika ankete koji dolaze iz različitih zemalja. To je ispitano t-testovima neovisnih uzoraka. Prosječne vrijednosti dane su u Tablici 6., a rezultati t-testova nalaze se u Tablici 7.

Tablica 6. Prosječne vrijednosti varijabli po zemljama

	Bosna i Hercegovina			Crna Gora			Hrvatska		
	Pros.	Std. dev.	St. greš. prosj.	Pros.	Std. Dev.	St. greš. prosj.	Pros.	Std. dev.	St. greš. prosj.
INT_RATE	0,4513	0,23493	0,02000	0,4482	0,21468	0,02126	0,5053	0,24024	0,01284
LOAN	0,2953	0,25270	0,02151	0,2745	0,23470	0,02324	0,3207	0,24181	0,01293
INVEST	0,4449	0,27208	0,02316	0,4157	0,26204	0,02595	0,4394	0,29917	0,01599

Izvor: izračun autora

Iz podataka se uočava da je u svim promatranim zemljama financijsko znanje koje se odnosi na skupinu pitanja o kamatnim stopama najbolje, a što je u skladu s nalazima Lusardi (2019) prema kojima je oko 50 % ispitanika u većini zemalja sposobno točno odgovoriti na postavljena pitanja o kamatnim stopama.

Tablica 7. Rezultati t-testova usporedbe prosječnih vrijednosti uparenih varijabli po zemljama

	t	df	Signif. (dvostrana)	Sredina, razlika.	Standardna greška, razlika.	95 % Interval pouzdanosti	
						Donja	Gornja
Rezultati ispitanika iz Bosne i Hercegovine u odnosu na ispitanike iz Crne Gore							
INT_RATE*	0,108	227,517	0,914	0,00317	0,02918	-0,05434	0,06067
LOAN	0,649	238	0,517	0,02078	0,03202	-0,04230	0,08386
INVEST	0,836	238	0,404	0,02924	0,03498	-0,03966	0,09814
Rezultati ispitanika iz Bosne i Hercegovine u odnosu na ispitanike iz Hrvatske							
INT_RATE	-2,248	486	0,025	-0,05396	0,02400	-0,10111	-0,00681
LOAN	-1,033	486	0,302	-0,02542	0,02462	-0,07380	0,02295
INVEST*	0,195	274,286	0,845	0,00550	0,02814	-0,04991	0,06091
Rezultati ispitanika iz Crne Gore u odnosu na ispitanike iz Hrvatske							
INT_RATE*	-2,300	181,195	0,023	-0,05713	0,02483	-0,10613	-0,00813
LOAN	-1,709	450	0,088	-0,04620	0,02703	-0,09933	0,00692
INVEST*	-0,779	184,601	0,437	-0,02374	0,03048	-0,08387	0,03639

Napomena: * označava rezultate bez pretpostavke jednakih varijanci (s obzirom na dobiti rezultat Levenova testa)

Izvor: izračun autora

Ovisno o rezultatu Levenova testa jednakosti varijance, u Tablici 7. objavljeni su rezultati uz pretpostavku jednakih, odnosno različitih varijanci za pojedine skupine (označeno * u tablici). Rezultati t-testova pokazali su da je jedino značajna razlika u poznavanju financija iz područja kamatne stope (INT_RATE), gdje hrvatski ispitanici postižu značajno bolje rezultate u odnosu na ispitanike iz Bosne i Hercegovine, ali i iz Crne Gore.

5. ZAKLJUČAK

Analiza financijske pismenosti učenika srednjih škola u Hrvatskoj, Bosni i Hercegovini i Crnoj Gori otkriva relativno nisku opću razinu financijske pismenosti u svim područjima financija (bez obzira na podrijetlo ispitanika), što daje izvjestan doprinos ovog istraživanja razumijevanju izazova i potreba koje treba adresirati kako bi se unaprijedila financijska pismenost mladih u ovim zemljama. Utvrđeno je da ispitanici zapravo nisu u dovoljnoj mjeri ni svjesni svoje financijske „nepismenosti“ jer svoje znanje ocjenjuju najčešće prosječnom ocjenom (45 %), a čak nešto više od 32 % ispitanika ocjenjuje ga kao iznadprosječno, dok je realno znanje suprotno od toga, jer je više od 70

% ispitanika ostvarilo rezultat ispod 50 % točnosti odgovora na postavljena financijska pitanja.

Manjkavost obrazovnog sustava po pitanju financijske pismenosti otkriva se i po tome što ispitanici izjavljuju da im roditelji predstavljaju glavni izvor financijskog znanja (46,8 %), dok se u školi educiraju u bitno manjoj mjeri o ovim pitanjima (15,6 %). Dobro je to što većina mladih ima iskustvo rada za novčanu naknadu (84 %) pa mogu lakše razumjeti zbog čega je potrebno upravljati novcem racionalno. Premda se očekivalo da će način na koji ispitanici stječu novac također imati bitan utjecaj na financijsku pismenost, hi-kvadrat testom to nije potvrđeno. Ono što je potvrđeno ovim testom jest da vrsta srednje škole utječe na financijsku pismenost u smislu da učenici iz četverogodišnjih strukovnih škola imaju veću razinu financijske pismenosti od učenika koji dolaze iz ostalih škola. Razlog tome može biti u izvedbenim programima tih škola koje ipak nude nešto više sadržaja iz ovog područja obrazovanja u odnosu na ostale vrste škola.

Promatrajući odvojeno po zemljama, rezultati istraživanja pokazuju da ne postoji statistički značajna razlika u razini financijske pismenosti među učenicima srednjih škola u Hrvatskoj, Bosni i Hercegovini i Crnoj Gori. Detektirana je jedino statistički značajna razlika u poznavanju financija iz skupine pitanja koja se odnose na kamatne stope (INT_RATE), gdje hrvatski ispitanici postižu nešto bolje rezultate u odnosu na ispitanike iz Bosne i Hercegovine, ali i Crne Gore.

Nedostaci provedenog istraživanja ogleda se u tome što je provedeno na relativno malom uzorku koji nije uzorkovan na uobičajeni statistički način slučajnog stratificiranog odabira, već su u istraživanju sudjelovali oni ispitanici koji su ujedno sudjelovali na radionicama financijske pismenosti u organizaciji djelatnika Odjela za ekonomiju i poslovnu ekonomiju Sveučilišta u Dubrovniku, a čije je znanje ispitano na početku održavanja radionica.

Uzevši u obzir specifičnosti pojedinih zemalja u pristupu edukacije o financijama, preporuke za poboljšanje uključuju integraciju relevantnih financijskih tema u kurikulum trogodišnjih strukovnih škola, kao i gimnazija, bolju prilagodbu nastavnih metoda te poticanje suradnje između obrazovnih institucija i financijskih stručnjaka.

Zaključno, ova komparativna analiza pruža osnovu za daljnje istraživanje i razvoj inicijativa koje će doprinijeti jačanju financijske pismenosti učenika u Hrvatskoj, Bosni i Hercegovini i Crnoj Gori s ciljem stvaranja generacija koje su

sposobne donositi informirane financijske odluke u sve kompleksnijem svjetskom ekonomskom okruženju.

REFERENCE

1. Allgood, S., & Walstad, W. B. (2016) The effects of perceived and actual financial literacy on financial behaviors. *Economic inquiry*, Vol. 54, No. 1, str. 675-697.
2. Balasubramnian, B., & Sargent, C. S. (2020) Impact of inflated perceptions of financial literacy on financial decision making. *Journal of Economic Psychology*, Vol. 80, 102306. Dostupno na: <https://doi.org/10.1016/j.joep.2020.102306> [12. studenoga 2023.]
3. Bottazzi, L., & Lusardi, A. (2021) Stereotypes in financial literacy: Evidence from PISA. *Journal of Corporate Finance*, Vol. 71, 101831. Dostupno na: <https://doi.org/10.1016/j.jcorpfin.2020.101831> [3. studenoga 2023.]
4. Burke, M. A. & Manz, M. (2011) Economic literacy and inflation expectations: Evidence from a laboratory experiment, *Federal Reserve Bank of Boston*, Public Policy Discussion Papers, No. 11-8, Boston, MA. Dostupno na: <https://www.econstor.eu/bitstream/10419/59212/1/672622068.pdf> [1. studenoga 2023.]
5. CBCG - Central Bank of Montenegro (2022) *Programme for Financial Education Development in Montenegro 2023-2027*. Dostupno na: https://www.cbcg.me/slike_i_fajlovi/eng/fajlovi/fajlovi_o_nama/corp_social_responsibility/financial_education/programme_for_financial_education_development_2023-2027.pdf [5. studenoga 2023.]
6. Chamboko, T. & Mutsonziwa, K. (2022): When more is more: why financial inclusion demand-side surveys are essential for access to financial services, *FinMark Trust*, Johannesburg, South Africa. Dostupno na: <https://finmark.org.za/knowledge-hub/blog/when-more-is-more-why-financial-inclusion-demand-side-surveys-are-essential-for-access-to-financial-services?entity=blog> [25. listopada 2023.]
7. Demertzis, M., Domínguez-Jiménez, M. & Lusardi, A. (2020) The financial fragility of European households in the time of COVID-19, *Bruegel Policy Contribution*, No. 15, str. 1-16. Dostupno na: <https://aei.pitt.edu/103258/1/PC%2D15%2D2020%2Dfinal.pdf> [2. studenoga 2023.]
8. Field, A. (2013) *Discovering statistics using IBM SPSS statistics*. sage.
9. Greene, W. H. (2000) *Econometric analysis 4th edition*. International edition, New Jersey: Prentice Hall, str. 201-215.
10. Halilović, S., Zaimović, A., Arnaut Berilo, A. & Zaimović, T. (2019) Financial Literacy Assessment in Bosnia and Herzegovina, *Procedia Computer Science*, 158, pp. 836-843. Dostupno na: https://www.researchgate.net/publication/336822119_Financial_Literacy_Assessment_in_Bosnia_and_Herzegovina [22. studenoga 2023.]
11. Hastings, J. S., Madrian, B. C. & Skimmyhorn, W. L. (2013) Financial Literacy, Financial Education, and Economic Outcomes, *Annual Review of Economics*, Vol. 5, str. 347-373. Dostupno na: <https://doi.org/10.1146/annurev-economics-082312-125807> [2. studenoga 2023.]

12. Henager, R. & Cude, B. J. (2016) Financial Literacy and Long- and Short-Term Financial Behavior in Different Age Groups, *Journal of Financial Counselling and Planning*, Vol. 27, No. 1, str. 3-19. Dostupno na: <http://dx.doi.org/10.1891/1052-3073.27.1.3> [1. studenoga 2023.]
13. Klapper L. & Lusardi, A. (2020) Financial literacy and financial resilience: Evidence from around the world, *Financial Management*, Vol. 49, No. 3, str. 589-614. Dostupno na: <https://doi.org/10.1111/fima.12283> [2. prosinca 2023.]
14. Lončar, I., Golemac, Z. & Arapović, A. (2017) Rezultira li srednjoškolsko obrazovanje zadovoljavajućom razinom financijskog znanja? u Blažić, H., Dimitrić, M. & Pečarić, M. (Ur.) *Financije na prekretnici: Imamo li snage za iskorak? In memoriam prof. dr. sc. Ivo Sever*, Rijeka: Sveučilište u Rijeci, Ekonomski fakultet str. 137-152.
15. Lusardi, A., Mitchell, O. S. & Curto, V. (2010) Financial literacy among the young, *Journal of consumer affairs*, Vol. 44, No. 2, str. 358-380. Dostupno na: <https://doi.org/10.1111/j.1745-6606.2010.01173.x> [22. studenoga 2023.]
16. Lusardi, A. & Mitchell, O. S. (2011) Financial literacy and retirement planning in the United States, *Journal of pension economics & finance*, Vol. 10, No. 4, str. 509-525. Dostupno na: https://www.nber.org/system/files/working_papers/w17108/w17108.pdf [19. listopada 2023.]
17. Lusardi, A. (2019) Financial literacy and the need for financial education: evidence and implications, *Swiss Journal of Economics and Statistics*, Vol. 155, No. 1, str. 1-8.
18. Lusardi, A. & Mitchell, O. S. (2023) The Importance of Financial Literacy: Opening a New Field, No. w31145, *National Bureau of Economic Research*. Dostupno na: https://www.nber.org/system/files/working_papers/w31145/w31145.pdf [20. studenoga 2023.]
19. OECD (2023) *OECD/INFE 2023 international survey of adult financial literacy*. Dostupno na: <https://www.oecd-ilibrary.org/docserver/56003a32-en.pdf?expires=1703615475&id=id&accname=guest&checksum=0F5C30E51E188B57E7E17803C5F4DC88> [1. prosinca 2023.]
20. OECD/INFE (2011) Measuring Financial Literacy: Core Questionnaire in Measuring Financial Literacy: Questionnaire and Guidance Notes for Conducting an Internationally Comparable Survey of Financial Literacy. Dostupno na: <https://www.oecd.org/finance/financial-education/49319977.pdf> [21. studenoga 2023.]
21. Raijas, A. (2021) Financial literacy and financial education in Northern Europe poglavlje u knjizi *The Routledge Handbook of Financial Literacy*, (ed. Nikolini, G. & Cude, B. J). Dostupno na: <file:///D:/Korisnik/Downloads/RoutledgeHandbooks-9781003025221-chapter24.pdf> [6. prosinca 2023.]
22. Stiglitz, J. E. (2008) Capitalist Fools, *Vanity Fair*, January 2009. Issue. Dostupno na: <https://www.vanityfair.com/news/2009/01/stiglitz200901-2> [15. studenoga 2023.]
23. Šubić, R., Balabanić, I., Ježovita, J. & Žagi, K. (2019) *Jesu li mladi danas dovoljno financijski pismeni*. Zagreb: Hrvatsko katoličko sveučilište.
24. Tinghög, G., Ahmed, A., Barrafreem, K., Lind, T., Skagerlund, K., & Västfjäll, D. (2021) Gender differences in financial literacy: The role of stereotype threat. *Journal of Economic Behavior & Organization*, Vol. 192, str. 405-416.

25. Vehovec, M., Rajh, E. & Škreblin Kirbiš, I. (2015) Financijska pismenost građana u Hrvatskoj, *Privredna kretanja i ekonomska politika*, Vol. 24, No. 1, str. 53-75.
26. Wooldridge, J. M. (2015) *Introductory econometrics: A modern approach*. Cengage learning.

COMPARATIVE ANALYSIS OF FINANCIAL LITERACY OF HIGH SCHOOL STUDENTS IN CROATIA, BOSNIA AND HERZEGOVINA AND MONTENEGRO

Associate Professor Tonći Svilokos, PhD

University of Dubrovnik, Department of Economics and Business

e-mail: tonci.svilokos@unidu.hr

Associate Professor Iris Lončar, PhD

University of Dubrovnik, Department of Economics and Business

e-mail: iris.loncar@unidu.hr

ABSTRACT

Financial literacy is a key component for the personal and economic success of individuals and plays an important role in modern society. Financially educated people are better able to plan for their future, which, in addition to their personal benefit, also implies the stability of the financial system and the state as a whole. As young people are a social group on which future development depends, they are the focus of this research. Therefore, the objectives of this paper are: i) to examine the level of financial literacy of high school students from Croatia, Bosnia and Herzegovina, and Montenegro, ii) to identify key areas in which students have the poorest knowledge, and iii) to compare the results of financial literacy in specific financial areas between students from each country. The research results show that there is no statistically significant difference in the level of financial literacy among students in Croatia, Bosnia and Herzegovina, and Montenegro. The only significant difference was found in financial literacy related to interest rates, where Croatian respondents achieved slightly better results compared to respondents from Bosnia and Herzegovina and Montenegro.

Keywords: financial literacy, financial knowledge, high school students, comparative analysis

JEL classification: G53, D14

UTJECAJ BIHEVIORALNIH PRISTRANOSTI NA EFEKT KRDA

dr. sc. Natali Brmalj

Sveučilište u Rijeci, Fakultet za menadžment u turizmu i ugostiteljstvu
e-mail: natalis@fthm.hr

SAŽETAK

Efekt krda proizlazi iz poteškoća u određivanju pravilnog smjera djelovanja zbog nedostatka informacija ili uvjerenja da drugi imaju bolje informacije. Iako postoje trenuci u kojima efekt krda može biti koristan na financijskim tržištima, navedeno nije uvijek takva okolnost. Unatoč sve većem broju istraživanja o bihevioralnim financijama, još uvijek nije dana perspektiva o povezanosti različitih teorija bihevioralnih financija kao što su teorija heuristike i prospektna teorija s efektom krda na tržištu kapitala. Stoga je svrha ovog rada istražiti utjecaj averzije prema riziku, averzije prema gubitku i heuristike reprezentativnosti na efekt krda institucionalnih investitora na tržištu kapitala u Hrvatskoj. Podaci su prikupljeni anketnim upitnikom¹ na uzorku od 119 ispitanika i analizirani su SmartPLS-om. Rezultati istraživanja otkrivaju prisutnost pozitivne i statistički značajne povezanosti između averzije prema gubitku i heuristike reprezentativnosti s efektom krda institucionalnih investitora na tržištu kapitala u Hrvatskoj. S druge strane, ne postoji statistički značajna povezanost između averzije prema riziku i efekta krda. Dobiveni rezultati istraživanja ključni su u kontekstu donošenja optimalnih investicijskih odluka svih sudionika na financijskom tržištu. Pažljivo analiziranje spomenutih bihevioralnih pristranosti važno je radi postizanja učinkovite diverzifikacije rizika i informiranog sudjelovanja na tržištu kapitala.

Ključne riječi: bihevioralne financije, efekt krda, averzija prema riziku, averzija prema gubitku, heuristika reprezentativnosti

JEL klasifikacija: G41, N24, D53, D91

¹ Analiza podataka temelji se na bazi podataka iz doktorske disertacije autorice Brmalj (2023)

1. UVOD

Diskusija između tradicionalnih teorija financija i bihevioralnih financija o utjecaju nefinancijskih čimbenika na cijene dionica još uvijek je aktualna. Iako je premisa neoklasičnih ekonomskih i financijskih teorija da se pojedinci ponašaju racionalno, navedeno u stvarnosti često nije slučaj. Tradicionalne teorije financija nisu uspjele objasniti tržišne anomalije na financijskim tržištima (Sharma i Kumar, 2020), stoga autori Barberis (2017) te Shefrin i Statman (2011) navode da se investitori ne ponašaju nužno racionalno kao što tvrde tradicionalne teorije financija. Promjene raspoloženja sudionika, efekt krda, psihološki čimbenici te emocije i kognitivne predrasude često su odgovorne za iracionalno ponašanje investitora (Shah *et al.*, 2018; Shefrin i Statman, 2011; Kahneman i Tversky, 1979). Velika ekonomska kriza 1929. godine, Azijska financijska kriza 1997. godine, financijska kriza 2008. godine i nedavna pandemija koronavirusa 2019. godine pokazale su da su financijska tržišta podložna utjecaju emocija i bihevioralnih pristranosti (Shrotryia i Kalra 2021). Tijekom nesigurnih razdoblja na tržištu, investitori s manje informacija nastoje replicirati ponašanje pojedinaca za koje smatraju da su informiraniji, što u konačnici rezultira efektom krda.

Prema Banerjee (1992) efekt krda jest postupak u kojem pojedinci oponašaju druge bez korištenja vlastitih informacija. Ovisi o stupnju neizvjesnosti, nedovoljnom znanju i manjem povjerenju u obradu informacija (Fernández *et al.*, 2011) te stvara nestabilnost na tržištu čak i ako je prisutan racionalan efekt krda (Din *et al.*, 2021). Kada je riječ o ulaganju, investitori nerijetko svoje odluke donose na temelju prošlih događaja (Busenitz, 1999), pokazuju averziju prema riziku i averziju prema gubitku preferirajući ujednačeniju i stabilniju percepciju rizika (Bailey *et al.*, 2011; Buesnitz, 1999; Kahneman i Tversky, 1979). Pregledom literature unutar bihevioralnih financija (Jan i Adil, 2022; Gupta i Shrivastava, 2022; Yadav i Narayanan, 2021; Caparrelli *et al.*, 2004; Ahmad i Wu, 2022; Bogdan *et al.*, 2022; Shah *et al.*, 2018; Nofsinger, 2005; Nofsinger i Sias, 1999) dolazi se do zaključka da se većina istraživanja uglavnom fokusira na ispitivanje postoji li efekt krda među investitorima prilikom donošenja investicijskih odluka. Međutim, relativno malo istraživanja provedeno je s ciljem istraživanja mogućeg odnosa između bihevioralnih pristranosti i efekta krda koje su proučavali znanstvenici kao što su Kahneman i Tversky (1979) te Tversky i Kahneman (1974). Doprinos ovog rada očituje se u dobivanju novih spoznaja iz područja bihevioralnih financija s naglaskom na zemlje u razvoju kao što je Hrvatska. Navedena problematika od posebne je važnosti i doprinosi razumijevanju ponašanja investitora. Utjecaj efekta krda na financijska tržišta nedvojbeno postoji, no

postavlja se pitanje koje su pristranosti povezane s efektom krda i samim time imaju li utjecaj na isti. S obzirom na nedostatak prethodnih istraživanja u ovom specifičnom području postavlja se glavno istraživačko pitanje:

Postoji li povezanost između heuristike reprezentativnosti, averzije prema riziku i averzije prema gubitku s efektom krda institucionalnih investitora na tržištu kapitala u Hrvatskoj?

Rad je podijeljen u pet poglavlja. Nakon uvodnih razmatranja, sljedeća poglavlja uključuju pregled literature i oblikovanje hipoteza, metodologiju i rezultate istraživanja te zaključak i diskusiju.

2. PREGLED LITERATURE I OBLIKOVANJE HIPOTEZA

Postoje dva istaknuta pristupa koja opisuju kako pojedinci donose odluke između rizičnih izbora. Jedan su algebarski modeli na kojima se temelji prospektna teorija, a drugi je heuristika. Prospektna teorija, poznata i kao teorija očekivanih izbora, predstavlja model donošenja odluka pod rizikom te naglašava asimetriju u percepciji pojedinaca prema gubicima i dobitcima (Kahneman i Tversky, 1979; Thaler, 1999). Polazeći od prospektne teorije, pretpostavljamo da pojedinci donose odluke po svom stavu prema mentalnom računovodstvu, averziji prema riziku i averziji prema gubitku. Posljedično, tijekom određenog vremena, pojedinci slijede druge te time dolazi do efekta krda. Općenito, teorija ističe da pojedinci intenzivnije reagiraju na gubitke u odnosu na dobitke. Kada govorimo o percepciji rizika, možemo zaključiti da se radi o dinamičnom procesu koji se može promijeniti u različitim situacijama. Tako povećana percepcija rizika dovodi do opreznijeg ponašanja na financijskim tržištima, što može dovesti do smanjenja financijskih transakcija i općenito manjeg ulaganja na burzi (Ahmad i Wu, 2022). Stoga, pojačana svijest o riziku može izazvati da investitori budu oprezniji, izbjegavajući rizične transakcije i smanjujući svoje aktivnosti na tržištu. Posljedično, kada sudionici na financijskom tržištu percipiraju niski rizik, često se javlja efekt krda. Navedeno znači da slijede trendove ili odluke drugih sudionika na tržištu, vjerujući da su rizici minimalni ili da drugi imaju informacije koje ih čine sigurnima. Efekt krda rezultat je slijeđenja većine, što može dovesti do situacije gdje tržište funkcionira na temelju kolektivnih odluka umjesto individualne analize rizika. Navedeno se također može tumačiti i u kontekstu averzije prema gubitku. Averzija prema gubitku odnosi se na tendenciju sudionika da imaju veći afektivni utjecaj u slučaju ostvarenja

gubitka u odnosu na dobitak jednake veličine (Banerji *et al.*, 2020). Tako sudionici na tržištu mogu biti oprezniji kada imaju veću percepciju gubitaka, što dovodi do smanjenja financijskih transakcija i općenito manjih ulaganja, slično kao i u kontekstu povećane percepcije rizika.

Heuristika se definira kao jednostavno pravilo koje pojedinci primjenjuju u procesu donošenja odluka u nesigurnim okruženjima, a zahtijeva kratko vrijeme za prikupljanje i obradu informacija (Barberis i Thaler, 2003; Kahneman i Tversky, 1982; Ritter, 2003; Hertwig i Pachuru, 2015). Bloomfield (2006) definira heuristiku kao prečac koji pojedinac koristi kako bi smanjio složenost problema s kojima se suočava. „Heuristika se, najkraće rečeno, može definirati kao proces donošenja odluka u stresnim situacijama, s malo informacija i pod pritiskom vremena (Brmalj, 2023)“. Pristranost reprezentativnosti, kao jedan od najčešćih primjera heuristika, prvi su opisali psiholozi Amos Tversky i Daniel Kahneman tijekom 70-ih godina prošlog stoljeća, a definiraju je kao mentalni prečac koji pojedinci koriste za donošenje brzih odluka između sadašnjih situacija i onih iz prošlosti. „Pristranost reprezentativnosti karakterizira se kao navika ljudi da karakteriziraju misli, događaje i razmišljanja na temelju prošlih događaja (Busenitz 1999, citirano u Brmalj 2023)“. Kada investitori ostvare uspjeh prilikom ulaganja, tada mogu generalizirati svoje pozitivno iskustvo na slične situacije, što ih može navesti da u budućnosti preferiraju slične vrste ulaganja. Primjerice, kada veliki broj sudionika na financijskom tržištu primijeti da je određena dionica u kratkom roku značajno povećala svoju vrijednost. Umjesto da svaki investitor pojedinačno analizira razloge povećanja, svoju odluku mogu temeljiti koristeći heuristiku reprezentativnosti i time percipirati sličnost između prijašnjih situacija i one trenutačne. Ako se veći broj investitora priključi kupnji te dionice, efekt krda se pojačava.

Rezultati istraživanja Alizada i Clarin (2018) ističu da postoji statistički značajna povezanost između averzije prema gubitku i efekta krda individualnih investitora na financijskom tržištu u Švedskoj. Handoyo *et al.* (2019) navode da bihevioralne pristranosti (usidrenost, averzija prema gubitku, iluzija kontrole i pretjerano samopouzdanje) imaju značajan utjecaj na efekt krda. Rezultati istraživanja Hascaryani i Maski (2021) potvrđuju pozitivan utjecaj faktora heuristike (pristranost reprezentativnosti, dostupnosti, pretjeranog samopouzdanja i usidrenja) na efekt krda i dispozicijski efekt. Autori Din *et al.* (2021) istražuju utjecaj bihevioralnih pristranosti na efekt krda kod islamskih financijskih proizvoda, te dolaze do rezultata da pristranost samo-pripisivanja, iluzija kontrole i dostupnost informacija imaju pozitivan i značajan utjecaj

na efekt krda. Istraživanje autora Bashir *et al.* (2013) imaju za cilj prepoznati utjecaj pretjeranog samopouzdanja, iluzije kontrole, samopripisivanja, zablude kockara i zablude vruće ruke. Autori navode da postoji statistički značajan i negativan odnos pristranosti samopripisivanja i efekta krda te statistički značajan i pozitivan odnos između pristranosti prekomjernog samopouzdanja i iluzije kontrole s efektom krda. Utjecaj ostalih navedenih biheviornalnih pristranosti na efekt krda nije evidentiran. Dennis i Strickland (2002) te Holmes *et al.* (2013) potvrđuju pojavu efekta krda kod institucionalnih investitora, dok Gavrilidis *et al.* (2013) naglašavaju namjerno slijeđenje efekta krda od strane institucionalnih investitora u Španjolskoj.


Rezultati istraživanja variraju i ovise o perspektivi i stajalištu sudionika. S obzirom na činjenicu da ponašanja investitora nisu potpuno racionalna, te s obzirom na važnost razumijevanja istih, u nastavku je postavljen model i hipoteze istraživanja:

H1. Averzija prema riziku ima utjecaj na efekt krda institucionalnih investitora.

H2. Heuristika reprezentativnosti ima utjecaj na efekt krda institucionalnih investitora.

H3. Averzija prema gubitku ima utjecaj na efekt krda institucionalnih investitora.

Shema 1. Model istraživanja



Izvor: izrada autora

3. METODOLOGIJA ISTRAŽIVANJA

Ovaj članak temelji se na analizi baze podataka koja proizlazi iz doktorske disertacije autorice Brmalj (2023). Korištenje prikupljenih podataka omogućilo je istraživanje povezanosti između heuristike reprezentativnosti (engl. *Representativeness* - REP), averzije prema riziku (engl. *Risk aversion* - RIA) i averzije prema gubitku (engl. *Loss aversion* - LA) s efektom krda (engl. *Herding behavior*). Podaci su prikupljeni strukturiranim upitnikom pomoću Likertove ljestvice slaganja od pet stupnjeva. Upitnik je kreiran uz određene modifikacije na temelju teorijskih i empirijskih saznanja prethodnih istraživačkih studija. Stavke upitnika koje se odnose na heuristiku reprezentativnosti sastoje se od triju indikatora (H10, H11, H12), a prilagođene su prema istraživanju autora Cao *et al.* (2021); Baker *et al.* (2020); Jain *et al.* (2020) i Waweru *et al.* (2008). Latentna varijabla averzija prema gubitku također se sastoji od triju indikatora (P5, P7, P8), a prema istraživanju autora Cao *et al.* (2021); Lütje (2009) i Waweru *et al.* (2008). Averzija prema riziku obuhvaća dva indikatora (P9 i P10), a temelji se na istraživanju autora Lütje (2009). Efekt krda kao endogena varijabla mjeri se pomoću pet indikatora (EK1, EK2, EK3, EK4, EK5) prema Metawa *et al.* (2019).

Ciljnu skupinu čine institucionalni investitori na tržištu kapitala u Hrvatskoj, a za istraživanje je korišten izvještaj Hrvatske udruge financijskih tržišta (2019) i e-mail adrese dostupne na službenim stranicama institucionalnih investitora (sveukupno 500 kontakata). Ispitivanje je provedeno u tri faze, od 11. travnja do 25. lipnja 2022. Ukupno je prikupljeno 130 anketa, pri čemu je 11 bilo nepotpuno i izuzeto iz analize. Konačni uzorak obuhvaćao je 119 valjanih anketa, što predstavlja stopu odgovora od 24 %.

Za testiranje hipoteza korištena je metoda parcijalnih najmanjih kvadrata modeliranja strukturalnim jednadžbama (engl. *Partial Least Squares Structural Equation Modeling* - PLS-SEM). PLS-SEM jest statistička tehnika koja se koristi za testiranje i procjenu kauzalnih odnosa korištenjem kombinacije statističkih podataka i kvalitativnih pretpostavki kauzalnosti, a uključuje elemente faktor-ske analize i regresije (Hair *et al.*, 2017). PLS-SEM model obuhvaća procjenu mjernog i strukturalnog modela, a u ovom istraživanju primijenjen je postupak koji je detaljnije opisan u Hair *et al.* (2017). PLS-SEM metodologija pruža mogućnost istraživanja novih ili nedovoljno istraženih konstrukata i teorija, stoga se smatra prikladnom za analizu primarnih podataka u ovom istraživanju, s obzirom na to da su bihevioralne financije relativno novo područje istraživanja.

4. REZULTATI ISTRAŽIVANJA

U Tablici 1. navedene su demografske osobine ispitanika, iz koje je vidljivo da muški ispitanici čine 67 % ukupnog uzorka, dok ženski čine 33 %. Većina ispitanika pripada dobnoj skupini između 41 – 61 godina (54 %) i 21 – 40 godina (45 %). Čak 55,5 % ispitanika ima završen preddiplomski/diplomski studij, što je bilo očekivano s obzirom na potrebno znanje i obrazovanje u području investiranja. Najveći broj ispitanika istraživanja zaposlen je u investicijskom fondu (53,8 %), nakon čega slijede mirovinski fondovi (25,2 %), i društva za upravljanje investicijskim fondovima (20,2 %). Najmanji broj ispitanika čine društva za osiguranje (0,8 %).

Tablica 1. Demografske karakteristike ispitanika


Obilježje	n	%
<i>Spol</i>		
muški	80	67,2
ženski	39	33,8
<i>Dob</i>		
< 20	1	0,8
21 – 40	54	45,4
41 – 60	64	53,8
> 61	0	0
<i>Stupanj obrazovanja</i>		
osnovna škola	1	0,8
srednja škola	2	1,7
stručni studij	3	2,5
preddiplomski/diplomski	66	55,5
poslijediplomski	47	39,5
<i>Zaposlenje u financijskoj instituciji</i>		
Investicijski fond	64	53,8
Društvo za upravljanje investicijskim fondom	24	20,2
Mirovinski fond	30	25,2
Društvo za osiguranje	1	0,8
Leasing društvo	0	0
Factoring društvo	0	0

Izvor: Brmalj (2023)

Za procjenu mjernog i strukturnog modela korišten je SmartPLS4. Mjerni model predstavlja povezanost između konstrukata i njihovih indikatora. S druge strane, strukturalni model opisuje odnose između konstrukata, a čine ga tri egzogena konstrukta (averzija prema riziku, heuristika reprezentativnosti i

averzija prema gubitku) i jedan endogeni latentni konstrukt (efekt krda). Procjena reflektivnog mjernog modela obuhvaća provjeru pouzdanosti indikatora (faktorska opterećenja), unutarnje dosljednosti konstrukta (engl. *Cronbach Alpha*), konvergentne prosječno ekstrahirane varijance (engl. *Average Variance Extracted* – AVE) te provjeru diskriminantne valjanosti modela (Hair *et al.*, 2017). Prema Hair *et al.* (2014) ako su vrijednosti indikatora faktorskih opterećenja $\geq 0,40$, Cronbach Alphe $\geq 0,60$ i AVE $\geq 0,50$ smatra se da je zadovoljena konvergentna valjanost i unutarnja dosljednost konstrukta. Procjena diskriminantne valjanosti testira se pomoću poprečnih faktorskih opterećenja (engl. *Cross Loadings*), Fornell-Larckerova kriterija i Heterotrait-monotrait omjera korelacije (HTMT) (Hair *et al.*, 2017). Ona govori razlikuju li se latentni konstrukti međusobno, odnosno mjere li isto (Hair *et al.*, 2017). Na Shemi 2. prikazani su rezultati procjene mjernog modela.

Shema 2. Mjerni model



Napomena:

EK – efekt krda; LA (engl. *Loss aversion*) – averzija prema gubitku; REP (engl. *Representativeness*) – heuristika reprezentativnosti; RIA (engl. *Risk aversion*) – averzija prema riziku
Izvor: autorov izračun

Iz Tablice 2. vidljivo je da se vrijednosti indikatora faktorskih opterećenja kreću u rasponu od 0,477 do 0,915, Cronbach Alphe u rasponu od 0,600 do 0,794 te AVE vrijednosti u rasponu od 0,508 do 0,718, čime se može tumačiti da je zadovoljena konvergentna valjanost modela i unutarnja dosljednost mjernog modela.

Tablica 2. Valjanost mjernog modela

Konstrukt	Indikatori	Faktorska opterećenja	Cronbach Alpha	Kompozitna pouzdanost	AVE
Averzija prema riziku	P9	0,915	0,624	0,835	0,718
	P10	0,774			
Reprezentativnost	H10	0,741	0,608	0,784	0,549
	H11	0,657			
	H12	0,816			
Averzija prema gubitku	P5	0,933	0,562	0,743	0,508
	P7	0,477			
	P8	0,653			
Efekt krda	EK1	0,596	0,794	0,850	0,534
	EK2	0,779			
	EK3	0,662			
	EK4	0,812			
	EK5	0,780			

Izvor: autorov izračun

U Tablici 3. prikazani su rezultati diskriminantne valjanosti modela iz koje je vidljivo da su vrijednosti poprečnih faktorskih opterećenja određenog konstrukta veće od opterećenja indikatora drugih konstrukata. AVE kvadratni korijen svakog konstrukta veći je od korelacija s drugim konstruktima, čime je ispunjen Fornell-Larckerov kriterij. Također, sve vrijednosti HTMT omjera manje su od 0,85, čime je utvrđena postojanost diskriminantne valjanosti reflektivnog mjernog modela.

Tablica 3. Diskriminantna valjanost modela

Poprečna faktorska opterećenja				
Indikatori	EK	LA	REP	RIA
EK1	0,596	0,057	0,092	0,091
EK2	0,779	0,188	0,155	0,225
EK3	0,662	0,050	0,217	0,298
EK4	0,812	0,451	0,327	0,152
EK5	0,780	0,322	0,318	0,176
P5	0,390	0,933	0,339	0,007
P7	0,115	0,477	0,018	-0,055
P8	0,144	0,653	0,368	0,205
H10	0,289	0,224	0,741	0,124
H11	0,146	0,049	0,657	0,348
H12	0,282	0,445	0,816	0,175

Poprečna faktorska opterećenja				
Indikatori	EK	LA	REP	RIA
P10	0,161	0,075	0,115	0,774
P9	0,253	0,023	0,281	0,915
Fornell Larckerov kriterij				
	EK	LA	REP	RIA
EK	0,730			
LA	0,363	0,713		
REP	0,341	0,365	0,741	
RIA	0,252	0,050	0,252	0,848
HTMT omjer korelacije				
EK				
LA	0,383			
REP	0,402	0,686		
RIA	0,351	0,228	0,439	
Napomena: podebljane vrijednosti označavaju da sve ostale vrijednosti unutar istog stupca moraju biti niže od podebljane vrijednosti				
EK – efekt krda				
LA (engl. <i>Loss aversion</i>) – averzija prema gubitku				
REP (engl. <i>Representativeness</i>) – heuristika reprezentativnosti				
RIA (engl. <i>Risk aversion</i>) – averzija prema riziku				

Izvor: autorov izračun

Nakon evaluacije mjernog modela, drugi korak obuhvaća evaluaciju strukturalnog modela. Evaluacija strukturalnog modela uključuje procjenu multikolinearnosti između latentnih konstrukata (engl. *Variance inflation factor* – VIF), procjenu značajnosti veze puta, izračun koeficijenta determinacije (R^2), izračun koeficijenta veličine utjecaja (f^2) i finalnu odluku o prihvatanju ili odbacivanju hipoteza (Hair *et al.*, 2014).

VIF vrijednosti nalaze se u rasponu od 1,088 do 1,891, čime se može zaključiti da ne postoji problem multikolinearnosti, s obzirom na to da su sve VIF vrijednosti manje od 5. U skladu s preporukama Hair *et al.* (2017), za procjenu značajnosti veza puta primijenjen je postupak *potpune bootstrapping procedure*, a model je testiran na razini značajnosti $p < 0.05$.

Tablica 4. Testiranje hipoteza

Hipoteze	β – izvorni uzorak	t - vrijednost	P - vrijednost	Odluka	R ²	f ²
H1: RIA → EK	0,190	1,835	0,067	N.S.	0,216	0,043
H2: REP → EK	0,190	2,089	0,037	✓		0,037
H3: LA → EK	0,284	2,707	0,007	✓		0,089

Napomena:

EK – efekt krda


LA (engl. *Loss aversion*) – averzija prema gubitkuREP (engl. *Representativeness*) – heuristika reprezentativnostiRIA (engl. *Risk aversion*) – averzija prema riziku

N.S – nije statistički značajno

Rezultati su statistički značajni na razini $p < 0,05$

Izvor: autorov izračun

Shema 3. Strukturalni model



Napomena: EK – efekt krda; LA (engl. *Loss aversion*) – averzija prema gubitku; REP (engl. *Representativeness*) – heuristika reprezentativnosti; RIA (engl. *Risk aversion*) – averzija prema riziku

Izvor: autorov izračun

Na osnovi rezultata iz Tablice 4. i Sheme 2. dolazi se do zaključka da averzija prema riziku nema statistički značajan utjecaj na efekt krda (H1: $t = 1,835$; $p = 0,067$) te se hipoteza H1 odbacuje. Nasuprot tome, postoji pozitivna i statistički značajna povezanost između heuristike reprezentativnosti i efekta krda (H2:

$t = 2,089$; $p = 0,037$). Navedeno je u skladu s istraživanjem autora Hascaryani i Maski (2021). Također, postoji pozitivna i statistički značajna povezanost između averzije prema gubitku i efekta krda ($H3$: $t = 2,707$; $p = 0,007$), što je u skladu s istraživanjem Handoyo *et al.* (2019) te Alizada i Clarin (2018). Na temelju prethodno navedenog, potvrđuju se hipoteze $H2$ i $H3$.

U društvenim i bihevioralnim znanostima Sarstedt *et al.* (2017) navodi granične vrijednosti koeficijenta determinacije od 0,26, 0,13 i 0,02 kao značajne, umjerene i slabe. Rezultati istraživanja pokazuju da se 22 % varijacije zavisne varijable može objasniti pomoću nezavisnih varijabli. Drugim riječima, heuristika reprezentativnosti, averzija prema riziku i averzija prema gubitku objašnjavaju određeni dio promjene koja se javlja u efektu krda. Rezultati koeficijenta veličine utjecaja prikazuju slab utjecaj između egzogenih i endogenog latentnog konstrukta.

5. ZAKLJUČAK I DISKUSIJA

Osjećaj neizvjesnosti navodi investitore da misle da su drugi informiraniji. Posljedično, investitori pokušavaju prikupiti informacije promatrajući ponašanje drugih sudionika na financijskom tržištu, što može dovesti do efekta krda. Veliki broj prethodnih istraživanja fokusira se na pitanje je li, na temelju dostupnih informacija, prisutan efekt krda na financijskim tržištima. Stoga je u ovom istraživanju naglasak na ispitivanju čimbenika koji utječu na efekt krda institucionalnih investitora na tržištu kapitala u Hrvatskoj te se u navedenom očituje doprinos ovog rada. Rezultati istraživanja pokazuju da ne postoji statistički značajna povezanost između averzije prema riziku i efekta krda implicirajući da averzija prema riziku nije ključni pokretač institucionalnih investitora da slijede krdo. S druge strane, evidentirana je statistički značajna i pozitivna povezanost između averzije prema gubitku i efekta krda. Navedeno nam govori da povećanje averzije prema gubitku povećava efekt krda. Pozitivna i statistički značajna povezanost između pristranosti reprezentativnosti i efekta krda implicira da se odluke institucionalnih investitora na tržištu kapitala u Hrvatskoj temelje na prethodnim rezultatima određenih sektora ili financijskih instrumenata te da slijede tržišne trendove. Ovaj rad doprinosi postojećoj literaturi o bihevioralnim financijama. Budući da efekt krda stvara nestabilnosti na financijskom tržištu, razumijevanje bihevioralnih pristranosti doprinosi ne samo akademskom znanju, nego pruža i praktične implikacije za sve sudionike na financijskom tržištu, omogućujući informiranije donošenje

investicijskih odluka i strategija upravljanja rizikom u dinamičnom okruženju burze. Potrebno je ukazati i na nekoliko ograničenja rada koje treba uzeti u obzir. Ovaj rad obuhvaća samo nekoliko bihevioralnih pristranosti koje utječu na efekt krda, a ciljnu skupinu obuhvaćaju institucionalni investitori. Stoga je preporuka da buduća istraživanja obuhvate druge pristranosti prospektne teorije i teorije heuristike te pristranosti individualnih investitora. Isto tako, bilo bi zanimljivo usporediti utjecaj bihevioralnih pristranosti na efekt krda individualnih s institucionalnim investitorima. Sljedeće ograničenje odnosi se na anketni upitnik, odnosno na nedostatak objektivnosti prilikom ispunjavanja upitnika. U budućim istraživanjima mogu se primijeniti metoda dubinskog intervjuja ili fokus grupa, čime bi se mogao pružiti detaljniji uvid u bihevioralne pristranosti. U kontekstu rezultata dobivenih na hrvatskom tržištu kapitala, buduća istraživanja mogla bi ispitati povezanost bihevioralnih pristranosti i efekta krda u zemljama u razvoju. Ova saznanja mogla bi biti od koristi svim sudionicima na financijskim tržištima.

REFERENCE

1. Ahmad, M. i Wu, Q. (2022) Does herding behavior matter in investment management and perceived market efficiency? Evidence from an emerging market, *Management Decision*, Vol. 60, No. 8, str. 2148-2173.
2. Alizada, Z. i Clarin, O. (2018) The Impact of Loss Aversion Bias on Herding Behavior of Young Swedish Retail Investors: A Behavioral Perspective on Young Swedish Retail Investors' Decision Making in the Stock Market.
3. Bailey, W., Kumar, A. i Ng, D. (2011) Behavioral biases of mutual fund investors, *Journal of Financial Economics*, Vol.102, No. 1, str. 1-27.
4. Baker, S. R., Bloom, N., Davis, S. J. i Terry, S. J. (2020) Covid-Induced Economic Uncertainty. *National Bureau of Economic Research*.
5. Banerjee, A. V. (1992) A simple model of herd behavior, *The Quarterly Journal of Economics* Vol. 107, str. 797-817.
6. Banerji, J., Kundu, K. i Alam, P.A. (2020) Influence of behavioural biases on investment behaviour, *SCMS Journal of Indian Management*, Vol. 17, No. 1, str. 81-98.
7. Barberis, N. (2017) *Behavioural Finance: Asset Prices and Investor Behavior*. New Haven, CT: Yale University.
8. Barberis, N. i Thaler, R. (2003) A survey of behavioral finance. *Handbook of the Economics of Finance*, 1, str. 1053-1128.
9. Bashir, T., Fatima, T., Ilyas, H. i Chudhary, A. (2013) Impact of cognitive profile and information uncertainty on herding behavior of investor, *Journal of Business and Management*, Vol. 16, No. 1, str. 68-74.

10. Bloomfield, R. J. (2006) Behavioral Finance. *Pacific-Basin Finance Journal*, Vol. 11, No. 4.
11. Bogdan, S., Suštar, N. i Draženović, B. O. (2022) Herding behavior in developed, emerging, and frontier European stock markets during COVID-19 pandemic, *Journal of Risk and Financial Management*, Vol. 15, No. 9, str. 1-12.
12. Brmalj, N. (2023) *Utjecaj bihevioralnih faktora na donošenje investicijskih odluka*. Doktorska disertacija. Sveučilište u Rijeci, Fakultet za menadžment u turizmu i ugostiteljstvu, Opatija.
13. Busenitz, L. W. (1999) Entrepreneurial risk and strategic decision making: It's a matter of perspective, *The Journal of Applied Behavioral Science*, Vol. 35, No. 3, str. 325-340.
14. Cao, M. M., Nguyen, N. T. i Tran, T. T. (2021) Behavioral factors on individual investors' decision making and investment performance: A survey from the Vietnam Stock Market, *The Journal of Asian Finance, Economics and Business*, Vol. 8, No. 3, str. 845-853.
15. Caparrelli, F., D'Arcangelis, A. M. i Cassuto, A. (2004) Herding in the Italian stock market: a case of behavioral finance. *The Journal of Behavioral Finance*, Vol. 52, No. 4, str. 222-230.
16. Dennis, P. J. i Strickland, D. (2002) Who blinks in volatile markets, individuals or institutions? *The Journal of Finance*, Vol. 57, No. 5, str. 1923-1949.
17. Din, S. M. U., Mehmood, S. K., Shahzad, A., Ahmad, I., Davidyants, A. i Abu-Ruman, A. (2021) The impact of behavioral biases on herding behavior of investors in Islamic financial products, *Frontiers in Psychology*, Vol. 11, str. 1-10.
18. Fernández, B., Garcia-Merino, T., Mayoral, R., Santos, V. i Vallelado, E. (2011) Herding, information uncertainty and investors' cognitive profile, *Qualitative Research in Financial Markets*, Vol. 3, No. 1, str. 7-33.
19. Gavrilidis, K., Kallinterakis, V. i Ferreira, M. P. L. (2013) Institutional industry herding: intentional or spurious? *Journal of International Financial Markets, Institutions and Money*, Vol. 26, str. 192-214.
20. Gupta, S. i Shrivastava, M. (2022) Herding and loss aversion in stock markets: mediating role of fear of missing out (FOMO) in retail investors, *International Journal of Emerging Markets*, Vol. 17, No. 7, str. 1720-1737.
21. Hair, J. F., Henseler, J., Dijkstra, T. K. i Sarstedt, M. (2014) Common beliefs and reality about partial least squares: comments on Rönkkö and Evermann. *Organizational Research Methods*, Vol. 17, No. 1, str. 182-209.
22. Hair, J. F., Sarstedt, M., Ringle, C. M. i Gudergan, S. P. (2017) *Advanced issues in partial least squares structural equation modeling*. Sage publications.
23. Handoyo, S. D., Rispantyo, R. i Widarno, B. (2019) Pengaruh Overconfidence, Illusion Of Control, Anchoring, Loss Aversion Pada Pengambilan Keputusan Investasi Oleh Mahasiswa Unisri Sebagai Investor Pemula. *Jurnal Akuntansi Dan Sistem Teknologi Informasi*, Vol. 15., str. 411-421.

24. Hascaryani, T. D. i Maski, G. (2021) Heuristic, herding and disposition effect in investor's risk-taking behavior, *International Journal of Economics, Business and Management Research*, Vol. 5, No. 12, str. 276-291.
25. Hertwig, R. i Pachur, T. (2015) Heuristics, history of. *International encyclopedia of the social & behavioral sciences*, Elsevier, str. 829-835.
26. Holmes, P., Kallinterakis, V. i Ferreira, M. L. (2013) Herding in a concentrated market: a question of intent. *European Financial Management*, Vol. 19, No. 3, str. 497-520.
27. Izvještaj Hrvatske udruge financijskih tržišta (2019), <https://acifma.hr/>
28. Jain, J., Walia, N. i Gupta, S. (2020) Evaluation of behavioral biases affecting investment decision making of individual equity investors by fuzzy analytic hierarchy process, *Review of Behavioral Finance*, Vol. 12, No. 3, str. 297-314.
29. Jan, N., i Adil, M. (2022) Behavior biases and investor investment decisions in Pakistan foreign exchange market, *Market Forces*, Vol. 17, No. 2, str. 25-42.
30. Kahneman, D. i Tversky, A. (1979) Prospect theory: an analysis of decision - making under risk. *Journal of Econometrica*, Vol. 47, No. 2, str. 263-291.
31. Kahneman, D. i Tversky, A. (1982) *Judgment under uncertainty : Heuristic and Biases*. Cambridge university press.
32. Lütje, T. (2009) To be good or to be better: asset managers' attitudes towards herding, *Applied Financial Economics*, Vol. 19, No. 10, str. 825-839.
33. Metawa, N., Hassan, M. K., Metawa, S. i Safa, M. F. (2019) Impact of behavioral factors on investors' financial decisions: case of the Egyptian stock market, *International Journal of Islamic and Middle Eastern Finance and Management*, Vol. 12, No. 1, str. 30-55.
34. Nofsinger, J. R. (2005) Social mood and financial economics, *The Journal of Behavioral Finance*, Vol. 6, No. 3, str. 144-160.
35. Nofsinger, J. R. i Sias, R. W. (1999) Herding and feedback trading by institutional and individual investors, *The Journal of Finance*, Vol. 54, No. 6, str. 2263-2295.
36. Ritter, J. R. (2003) Behavioral finance, *Pacific-Basin Finance Journal*, Vol. 11, No. 4, str. 429-437.
37. Sarstedt, M., Ringle, C. M. i Hair, J. F. (2017) Partial least squares structural equation modeling. *Handbook of market research*. Cham: Springer, str. 587-632.
38. Shah, S. Z. A., Ahmad, M. i Mahmood, F. (2018) Heuristic biases in investment decisionmaking and perceived market efficiency: A survey at the Pakistan stock exchange, *Qualitative Research in Financial Markets*, Vol. 10, No. 1, str.85-110.
39. Sharma, A. i Kumar, A. (2020), A review paper on behavioral finance: study of emerging trends, *Qualitative Research in Financial Markets*, Vol. 12, No. 2, str. 137-157.
40. Shefrin, H. i Statman, M. (2011) Behavioural finance in the financial crisis: market efficiency, Minsky, and Keynes, *Santa Clara University*, str. 1-62.
41. Shrotryia, V. K. i Kalra, H. (2021) Herding in the crypto market: A diagnosis of heavy distribution tails. *Review of Behavioral Finance*, Vol. 14, No. 5, str. 566-587.

42. Thaler, R. H. (1999) The end of behavioral finance, *Financial Analysts Journal*, Vol. 55, No. 6, str. 12-17.
43. Tversky, A. i Kahneman, D. (1974) Judgment under Uncertainty: Heuristics and Biases: Biases in judgments reveal some heuristics of thinking under uncertainty. *Science*, Vol. 185, No. 4157, str. 1124-1131.
44. Waweru, N. M., Munyoki, E. i Uliana, E. (2008) The effects of behavioural factors in investment decision-making: a survey of institutional investors operating at the Nairobi Stock Exchange. *International Journal of Business and Emerging Markets*, Vol. 1, No. 1, str. 24-41.
45. Yadav, A. i Narayanan, G. B. (2021) Do personality traits predict biasedness while making investment decisions? *International Journal of Accounting & Finance Review*, Vol. 6, No. 1, str. 19-33.

THE IMPACT OF BEHAVIOURAL BIASES ON HERD BEHAVIOR

Natali Brmalj, PhD

University of Rijeka, Faculty of Tourism and Hospitality Management

e-mail: natalis@fthm.hr

ABSTRACT

Herd behaviour results from the difficulty in determining the right course of action due to a lack of information or the belief that others have valuable information. Although herd behaviour can sometimes be beneficial in financial markets, it is not always an inevitable circumstance. Despite the increasing research in the field of behavioural finance, there is still no comprehensive perspective on the link between different theories of behavioural finance, namely the theory of heuristics, prospect theory, and herding behaviour in the capital market. The aim of this paper is therefore to investigate the influence of risk aversion, loss aversion, and the representativeness heuristic on the herding behaviour of institutional investors in the Croatian capital market. The data was collected from 119 respondents using a questionnaire and analysed using SmartPLS. The research results show that there is a positive and statistically significant relationship between loss aversion and the representativeness heuristic with the herding behaviour of institutional investors in the Croatian capital market. In contrast, there is no significant relationship between risk aversion and herding behaviour. The research findings are crucial for the optimal investment decisions of all participants in the financial market. A careful analysis of the above-mentioned behaviours is important for achieving effective risk diversification and informed participation in the capital market.

Keywords: behavioural finance, herd behaviour, risk aversion, loss aversion, representativeness heuristic

JEL classification: G41, N24, D53, D91

BIHEVIORISTIČKE SPOZNAJE U POREZNOJ POLITICI¹

prof. dr. sc. Renata Perić

Sveučilište Josipa Jurja Strossmayera u Osijeku, Pravni fakultet Osijek
e-mail: rperic@pravos.hr

izv. prof. dr. sc. Emina Jerković

Sveučilište Josipa Jurja Strossmayera u Osijeku, Pravni fakultet Osijek
e-mail: ekonjic@pravos.hr

SAŽETAK

U radu će biti govora o sve važnijoj temi, a to je pojam bihevioralnog oporezivanja. Svrha rada jest ukazati na važnost ovog relativno novog pojma u oporezivanju kojim se ne želi postići samo primaran fiskalni cilj oporezivanja nego i utjecati na nezadovoljstvo poreznih obveznika vezano za ispunjavanje neminovnih poreznih obveza. Također je kroz bihevioralno oporezivanje protkan pojam poreznog morala na koji se može utjecati putem financijskog i poreznog opismenjavanja pa posljedično i na ponašanje poreznog obveznika kod kojeg se neizbježno u većoj ili manjoj mjeri uvijek javlja otpor prilikom ispunjavanja porezne obveze. U radu se koriste metode analize, komparacije i dedukcije.

Ključne riječi: ciljevi oporezivanja, bihevioralno oporezivanje, porezni moral, ponašanje poreznih obveznika

JEL klasifikacija: G41, K34

1. UVOD

Svaka država suočena sa svojim jedinstvenim problemima mora postaviti pred sebe zadatak rješavanja tih problema u vidu postavljanja objektivno ostvarivih

¹ Ovaj je rad financirao Pravni fakultet Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku internim projektom br. IP-PRAVOS-21 „Fiskalna politika i razvoj sustava javnih financija“.

ciljeva. Za rješavanje tih istih problema potrebno je i znanje i iskustvo vladajućih koji se neminovno isprepliću s brojnim faktorima, kao što su utjecaj moći, interesne skupine, političke stranke, pripadnost i približavanje raznim ekonomskim interesnim grupacijama (npr. EU, OECD i sl.), sveukupno stanje u državi, stručnost, obrazovanje i opremljenost kadra, razni vanjski utjecaji poput položaja države, blizina ratnih žarišta, utrka u naoružanju, odnosi sa susjednim državama i slično. Kao jedan od načina realiziranja postavljenih ciljeva i rješavanja problema jest oporezivanje (Jerković, 2017).

Kako bi se postiglo bolje izvršavanje plaćanja poreza, porezne uprave trebale bi se koristiti novim načinima suradnje s poreznim obveznicima, primjerice, primjenom biheviornalnog pristupa ili suradnje pri izvršavanju obveza (Europska komisija, 2020).

Iznos dospelog poreza trebao bi biti točan od samog početka kako bi se izbjeglo da porezni obveznici moraju tražiti i čekati povrat (Europska komisija, 2020, str. 10).

Na spremnost poreznih obveznika da plate porez utječu mnogi faktori vezani za financijsku i poreznu pismenost, a neki od njih su visina porezne obveze, osobna stajališta, svrha u koju odlaze oporezivana sredstva, nepovjerenje u državnu vlast i sl. Plaćanjem poreza dolazi do smanjenja obveznikove ekonomska snage, što lako dovodi do djelomičnog ili potpunog izbjegavanja plaćanja poreza ako porezni obveznik nije svjestan svrhe u koju se porezom ubrana sredstva planiraju utrošiti, odnosno ne vidi uzročno-posljedičnu vezu između plaćanja poreza i koristi koju ostvaruje putem korištenja javnih usluga pruženih od strane države i jedinica lokalne i područne samouprave.

2. CILJEVI OPOREZIVANJA

Od svojih početaka, porezi su od sekundarnog i neredovitog prihoda države, ubiranog od samo određenog kruga ljudi za konkretne svrhe države i dvora, evoluirali u redovite i iznimno značajne prihode koji se ubiru i od građana i od pravnih osoba za mnogobrojne različite državne rashode (Jelčić i dr., 2008, str. 79).

Mjesto, uloga, funkcija, zadaci i ciljevi oporezivanja nisu oduvijek bili jednaki. Prema J. Bodinu, porezi su u sustavu javnih prihoda smješteni na posljednje, sedmo mjesto, što znači da nije bio izražen njihov fiskalni karakter, već karak-

ter supsidijarnog prihoda.² Od tada su porezi na ljestvici važnosti javnih prihoda napredovali do prvog mjesta te se smatraju najizdašnjim javnim prihodom i upravo je zato od iznimne važnosti da se prikupljanjem poreza ne ostvaruje samo fiskalni cilj već i mnogi drugi ciljevi, od kojih je jedan od najvažnijih socijalni cilj oporezivanja.

Oporezivanjem se ostvaruju mnogi ciljevi od kojih je najvažniji, dakako, fiskalni cilj, odnosno namicanje dovoljno novca u državnu blagajnu radi zadovoljenja javnih potreba. Osim toga najvažnijeg cilja, oporezivanjem se mogu postići i mnogi drugi važni ciljevi kojima se želi utjecati na samo ponašanje poreznog obveznika, a koji mogu biti, a često i jesu, u izravnom sukobu kako međusobno tako i s fiskalnim ciljem oporezivanja koji je povijesno daleko najbitniji, a često je i predstavljao isključiv cilj oporezivanja. Sve veće potrebe i razvoj suvremenog društva nametnule su i potrebu za ostvarivanje i nekih ne nužno fiskalnih ciljeva. Tu se mogu izdvojiti socijalni, politički, demografski, ekonomski, pedagoški, ekološki i mnogi drugi ciljevi.

Mjesto i uloga poreza su se tijekom povijest podvrgnuli mnogim promjenama, uglavnom prouzročenim promjenama u društvenom, ekonomskom i političkom sustavu zemalja. S obzirom na to da je ostvarenje ciljeva usko povezano s ulogom države, širenjem uloge države povećavaju se i njezine novčane potrebe. Osim financijske, porezima se namijenila i ekonomska uloga te tako oni postaju instrument politike cijena, sredstvo usklađivanja ponude i potražnje, sredstvo usmjeravanja investicija i ograničavanja stopa inflacije, sredstvo smanjenja stope nezaposlenosti, ali i rješenje pri postizanju bržeg i skladnijeg razvoja zemlje.

Prilikom rasprave o ciljevima oporezivanja treba voditi računa da se:

- jednim te istim porezom može ostvariti više ciljeva
- jedan te isti cilj može ostvariti primjenom različitih poreza
- jedan te isti cilj može ostvariti ne samo oporezivanjem nego i/ili primjenom i drugih mjera iz bogatog arsenala mjera kojima raspolaže država (Jelčić i dr., 2008, str. 206).

Prema cilju koji se porezom nastoji postići, poreze dijelimo na:

² J. Bodin smatra da postoji sedam izvora državnih prihoda u apsolutizmu: 1. domene, 2. ratni plijen, 3. darovi prijatelja i podanika te oporučna ostavljanja, 4. razni oblici pomoći saveznika, 5. prihodi od državne trgovine, 6. uvozne i izvozne carine, 7. porezi podanika (Jelčić, B. (2001) prema Mann, F. K. (1937) *Steuerpolitische Ideale*, Jena, str. 40.)

1. fiskalne koji služe isključivo ili većinski za prikupljanje sredstava za financiranje javnih rashoda
2. nefiskalne koji služe za poticanje određenih promjena u ponašanju i radu poreznih obveznika (Jelčić i dr., 2008, str. 206).

Sve veće potrebe i ubrzani razvoj suvremenog društva nametnule su i potrebu za ostvarivanjem i nekih ne nužno fiskalnih ciljeva. Nefiskalni ciljevi mogu biti ekonomski, politički, pedagoški, socijalni, ekološki i drugi ciljevi (npr. poticanje stambene izgradnje, unapređivanje kulturne i sportske djelatnosti), a nerijetko su u koliziji s primarnim fiskalnim ciljem oporezivanja te je njihov je cilj stimuliranje poreznog obveznika na određeno ponašanje (Jerković, 2017, str. 218).

Kao primjer može se navesti poseban porez (trošarina) na alkohol. Fiskalni ciljevi, odnosno povećanje javnih prihoda, gotovo uvijek predstavljaju glavni razlog uvođenja poreza. Međutim, oporezivanje alkohola generira razne socijalne, zdravstvene i ekonomske učinke (Sopek, 2013, str. 9). Ciljevi primjene posebnih poreza na alkohol mogu biti različiti, npr. pedagoški u vidu poticanja smanjenja potrošnje gdje je vidljiv i zdravstveni i socijalni motiv, zatim poništavanje svih eksternih i ukupnih društvenih troškova, gdje su vidljivi ekonomski i socijalni motiv. Brojne studije (Smith, 2005; Cnossen, 2006; Rabinovich i dr., 2012) pokazuju postojanje negativne elastičnosti potrošnje alkohola na cijenu. To znači da rast cijena alkoholnih pića uzrokuje smanjenje potrošnje. Elastičnost varira ovisno o vrsti alkoholnih pića; najmanja je uglavnom kod piva, a najveća u žestokih alkoholnih pića (Sopek, 2013, str. 2). Također, dugoročna cjenovna elastičnost potražnje za alkoholom viša je od kratkoročne, a ljudi koji tek povremeno piju cjenovno su osjetljiviji od onih koji piju češće (Cnossen, 2006, str. 23-25). Drugim riječima, pitanje potrošnje značajno ovisi o ponašanju i navikama potrošača (poreznih destinatarata posebnih poreza). Kad je ponašanje poreznih obveznika u pitanju, neminovno se mora spomenuti i prekograničnu kupnju raznih, često povoljnijih proizvoda, u ovom slučaju alkoholnih pića, koja, ovisno o moralu poreznih obveznika, često vodi do nezakonite porezne evazije u vidu kontrabande.

U vezi s (višim) razinama cijena javlja se još jedna ekonomski nepovoljna pojava – rast legalne prekogranične trgovine, a posebice ilegalnih aktivnosti poput krijumčarenja i ostale porezne evazije.³ Upravo je uz ponašanje potrošača

³ London Economics (2010: 56) prema radu Sopek (2013) pokazuje da su zemlje s najvišim diferencijalima cijena ujedno i zemlje s najvišim udjelima prekogranične trgovine alkohola.

vezan i porezni moral. Velik problem sustava oporezivanja alkohola posebnim porezima predstavlja gubitak prihoda od te vrste poreza (čime se ne ispunjava u potpunosti fiskalni cilj oporezivanja) zbog legalne prekogranične prodaje, ali i ilegalnih aktivnosti poput krijumčarenja. Stoga, sve zemlje članice, a posebice one s visokim trošarinama, moraju uložiti dodatne napore za uspostavu pravovaljanih internih kontrola. Sve zemlje članice EU-a koje graniče s trećim zemljama moraju pojačati kontrole i interne potrošnje i krijumčarenja iz susjednih zemalja te tako doprinijeti zaustavljanju odljeva iz njihovih teritorija (Sopek, 2013, str. 9).

3. OTPOR PRILIKOM PLAĆANJA POREZA

Kod velike većine građana – poreznih obveznika, neovisno o njihovu materijalnom položaju i poreznom odredištu, postoji više ili manje izražen otpor plaćanju poreza. Imajući na umu da poreze, između ostalog, karakteriziraju prisilnost, derivativnost, nedostatak ekvivalencije i nepovratnost, ne smije iznenaditi da porezni obveznici razvijaju negativan stav prema njihovu plaćanju.

Obveznici poreze doživljavaju kao napad na osobnu slobodu i privatni život i vlasništvo. Što su porezni teret, zadiranje države u privatnost i zahvaćanje dohotka i/ili imovine veći, to je veći i otpor. Otpor plaćanju poreza nije novost. Star je koliko su stari i porezi. Izvori o porezu sežu još u Mezopotamiju te svjedoče brojnim ustancima, seljačkim bunama, iseljavanjima i promjenama u socijalnim, ekonomskim i političkim sferama koje su porezi uzrokovali od svog nastanka. Neki od najpoznatijih primjera u povijesti zasigurno su Francuska revolucija iz 1789. godine te Bostonska čajanka iz 1773. godine, čiji su korijeni ležali upravo na ovom otporu (Jelčić i dr., 2008, str. 210-211).

Uzimajući u obzir da se otpor javlja kod plaćanja svih poreznih oblika, u svim poreznim sustavima i kod većine poreznih obveznika, korisno je znati neka od njegovih osnovnih obilježja:

1. što je porezni teret veći, to je veći otpor poreznog obveznika
2. što je odstupanje od kriterija pravednosti veće, to je veći otpor jer se porezni obveznik smatra zaknutim
3. otpor ovisi o svrsi trošenja ubranih sredstava, o čemu svjedoči sve veća zainteresiranost poreznih obveznika. Također je važno napomenuti teoriju o dobrovoljnom ispunjavanju poreznih obveza (engl. *voluntary*

tax compliance) – koncept polazi od uzročno-posljedične povezanosti između plaćanja poreza i pružanja ekvivalencije u vidu pružanja javnih usluga kako od strane države tako i od strane jedinica lokalne i područne samouprave.⁴

4. otpor ovisi o poreznom moralu koji varira od podneblja do podneblja
5. otpor ovisi o poreznom obliku i tehnici oporezivanja, pri čemu se prvenstveno misli na prevaljivost poreza i vrstu porezne stope
6. otpor ovisi o stručnosti, savjesnosti i objektivnosti porezne administracije, kao i o njezinu odnosu prema obveznicima (Jerković, 2018, str. 993).

4. POREZNI MORAL

Porezni moral predstavlja subjektivan stav poreznog obveznika prema plaćanju poreza i njegovoj visini, na temelju razine njegova obrazovanja i društvenog statusa, raspodjele oporezivanih sredstava te straha od kazne u slučaju neispunjenja porezne obveze. Ako porezni obveznik pronalazi razne načine izbjegavanja plaćanja poreza, postoji mogućnost utaje (s obzirom na to da je vrlo tanka granica između dopuštene i nedopuštene evazije), što ukazuje na nisku svijest o potrebi plaćanja poreza (Mahović-Komljenović, 2009, str. 182).

Izraz porezni moral 1960. godine skovao je Schmolders (1960), koji ga definira kao „stav skupine ili cjelokupne populacije poreznih obveznika u pogledu izvršenja ili zanemarivanja svojih poreznih obveza; ukorijenjen je u poreznom mentalitetu građana i u njihovoj svijesti, što čini temelj njihova unutarnjeg prihvatanja poreznih obveza i priznavanja fiskalnog suvereniteta države“.⁵

Prema Kirchleru (2007, str. 130), porezni obveznik može dobrovoljno odlučiti platiti porez ili donijeti izričitu odluku o izbjegavanju plaćanja poreza. Neplaćanje poreza od strane jedne osobe zapravo ne čini veliku razliku u ukupnosti

⁴ Vidjeti više: Mahnire J. T. (2015-2016) *What Does Voluntary Tax Compliance Mean: A Government Perspective*, 164 U. Pa. L. Rev. Online 11; Ledreman, L. (2018) *Does Enforcement Reduce Voluntary Tax Compliance*, 2018, BYU L. Rev. 623; Muehlbacher, S., Kirchler, E. i Schwarzenberger, H. (2011) *Voluntary versus enforced tax compliance: empirical evidence for the „slippery slope“ framework*. Eur J Law Econ 32.

⁵ Prema Kirchleru (2005), pojam poreznog morala prvi je proučavao Strümpel (1966, 1969), a poslije Vogel (1974), Lewis (1982), Frey (1997), Frey i Eichenberger (2002), Torgler (2002) te Braithwaite i Ahmed (2005). Vidjeti više: Kirchler E. (2007) *The Economic Psychology of Tax Behaviour*. Cambridge University Press, 2007: i-iv.

naplaćenih javnih prihoda. Ako nekoliko poreznih obveznika utaji porez, javna dobra neće nestati niti će biti znatno smanjena. Problem, međutim, nastaje ako znatan broj poreznih obveznika ne plati porez. U tom slučaju, pretpostavka financiranja javnih potreba nije zajamčena i, u konačnici, svi će patiti od izbora onih koji nisu podmirili svoju poreznu obvezu. Porezni obveznici tako riskiraju određeni gubitak u visini plaćene porezne obveze ili, u slučaju porezne evazije, riskiraju nepromijenjeno financijsko stanje ako ostanu neotkriveni ili, u slučaju da ih se otkrije prilikom evazije poreza, riskiraju značajan financijski gubitak popraćen i raznim vrstama sankcija.

Spremnost na plaćanje poreza može biti i rezultat spomenutog straha od različitih negativnih posljedica, tj. kazni za neplaćanje ili zakašnjenje u plaćanju poreza, što uzročno-posljedično utječe i na društveni ugled poreznih obveznika (Jelčić i dr. 2008, str. 214).

I tu se zapravo nameće pitanje kako svijet reagira na nedostatak poreznog morala. Manje države otvaraju širom vrata multinacionalnim kompanijama jer tako žele osnažiti potrošačko tržište i ubiranjem PDV-a osigurati novac za razvoj. Zajednice država kakva je i Europska unija, nemaju jedinstvenu politiku oko poreza na dobit (jer se države ne mogu oko toga složiti zbog vlastitih interesa, a nerijetko jedna drugoj niskim porezima na dobit otimaju investitore). Pri tome je važno istaknuti da se upravo iz poreza u državnom proračunu formiraju sredstva za javne usluge (zdravstvo, socijala, kultura, znanost, obrazovanje), pa tako porezi postaju porezni instrumenti brojnih politika nacionalnih država od javnog zdravstva do socijale. Osim toga, ovakav pristup slabi i porezni moral običnih građana, koji nerijetko, kada mogu, izbjegavaju plaćanje poreza.⁶

Ako je porezni moral visok, znači da neće doći do otpora plaćanju poreza. Pri tom se visoki moral manifestira tako da:

1. porezni obveznici svjesni su da školovanje njihove djece, zaposlenost, sigurnost zemlje i ostali javni interesi iz nadležnosti države ovise o plaćanju poreza
2. porezni obveznici vjeruju da je porezni teret pravedno, ravnomjerno i svrsishodno raspoređen

⁶ Sindikat grafičara i medija, *Porezni nemoral u doba korone – Zar je novac važniji od ljudskog života?*, <https://www.sgim.hr/porezni-nemoral-u-doba-korone-zar-je-novac-vazniji-od-ljudskog-zivota/1997/>. [Pristupljeno 30. 11. 2023.]

3. plaćanje poreza povezano je s nekom etičkom, patriotskom ili drugom svrhom
4. ubrzani porez daje se osobama koje su pogođene elementarnim nepogodama i drugim sličnim nesretnim okolnostima ili, ako se taj iznos troši, radi nacionalne sigurnosti (Jelčić, B., 2001, str. 144).

Koristeći imigrantske podatke iz Europskog socijalnog istraživanja za ispitivanje uloge kulture u oblikovanju poreznog morala, Kountouris i Remoundou (2013, str. 104) navode da „razina poreznog morala u zemlji imigrantskog podrijetla utječe na individualni porezni moral u zemlji odredišta“.

4.1. POREZNI MORAL NA EUROPSKOJ RAZINI

Zbog svega navedenog, porezni moral podosta varira od zemlje do zemlje.

Barr i Serra (2010) iznose rezultate svog eksperimenta vezanog za igre podmićivanja koji je bio proveden u Ujedinjenom Kraljevstvu nad studentima iz 34 različite zemlje. Analiza rezultata pokazala je da, kad su u pitanju studenti pred-diplomskog studija, ponašanje pojedinaca u eksperimentu može se predvidjeti s obzirom na razinu korupcije u njihovim zemljama porijekla. Autori tvrde da ovi nalazi pokazuju veliki utjecaj kulturnog okruženja i društvenih normi na ponašanje te naglašavaju kulturni aspekt koruptivnog ponašanja. Također su otkrili da studenti diplomskih studija koji žive u Ujedinjenom Kraljevstvu dulje nego studenti preddiplomskih studija prilagođavaju svoje ponašanje tako da razine korupcije u njihovoj zemlji porijekla više ne mogu predstavljati takvo ponašanje. Autori tvrde da su tijekom vremena u Ujedinjenom Kraljevstvu studenti možda usvojili domaći set vrijednosti. Slični kulturološki učinci mogu utjecati na ispunjavanje poreznih obveza pojedinaca (Weber, Fookien, i Herrmann, 2014, str. 20).

Prema tvrdnji Gadže (2020), Republika Hrvatska mora kontinuirano raditi na jačanju poreznog morala kod poreznim obveznika, ali i uz obvezno pojačanu moralnu i političku odgovornost dužnosnika na transparentno i učinkovito trošenje državnih prihoda.

Prema istraživanju Rimca i Štulhofera iz 2002. godine, Republika Hrvatska dvostruko je lošija od prosjeka EU-a po tom pitanju. S time da ni povjerenje u političke institucije nije na mnogo višoj razini. Građanima je od velikog značaja pitanje pravde i opravdanosti socijalnih normi, a time i povjerenje u zakon-

ske odredbe. Ako tog povjerenja nema, prilike za izbjegavanje plaćanja poreza naglo rastu (Bejaković, 2009, str. 795-797).

5. BIHEVIORALNA EKONOMIJA I BIHEVIORALNE FINACIJE

Bihevioralna ekonomija proučava utjecaj psiholoških, socijalnih, kognitivnih i emotivnih faktora na naše odluke (primarno ekonomske, ali ne i samo na njih). Konkretno, primjena znanja iz područja bihevioralne ekonomije može utjecati na građane da, bez prisile i bez manipulacije, donosu bolje odluke u svakodnevnom životu.

Weber (2005), kako je navedeno u radu Horonitz (2013), bihevioralnu ekonomiju definira „kao kombinaciju ekonomije i drugih društvenih znanosti koje više opisuju ponašanje. Javlja se kad ekonomisti kombiniraju istraživanja i metode iz ekonomije i drugih društvenih znanosti s ciljem poboljšavanja deskriptivne vrijednosti ekonomske teorije“. Horonitz također navodi da „bihevioralna ekonomija nije posebno polje ekonomije. To je stil modeliranja ili škola mišljenja koja znači primjenu na veliko područje ekonomskih pitanja u teoriji potrošača, financija, poreznoj politici itd. Psihologijski rezultati doprinose razvoju bihevioralne ekonomije brojnim eksperimentima gdje je bihevioralna ekonomija pristup, a eksperimentalna ekonomija je metoda“.

Kad promatramo skup znanja o financijama, bihevioralne financije predstavljaju nov pristup području financija. Tradicionalno se smatra da, pri odlučivanju u uvjetima neizvjesnosti, ljudi oblikuju stavove u skladu sa zakonima vjerojatnosti i da se pri tome vode isključivo maksimizacijom osobnih interesa. Međutim, ne treba zanemariti i značaj intuicije, prema kojem zaključivanje i donošenje odluka dolazi spontano, bez iscrpnog razmišljanja i napora (Brajković i Radman Peša, 2015, str. 69). Prema Vučkoviću (2010), kako je navedeno u radu Brajković i Radman Peša (2015), znanstvene discipline koje proučavaju ljudsko ponašanje (medicina, psihologija, sociologija i antropologija) mogu mnogo pomoći u proučavanju deskriptivnog procesa odlučivanja. Bihevioralne financije istražuju utjecaj psihologije na ponašanje sudionika tržišta, koncentrirajući se na to kako individualni investitori donose odluke, to jest kako interpretiraju i reagiraju na određene informacije (Park i Sohn, 2013). Kapor (2014) objašnjava kako ekonomski posrednici raspolazu ograničenom pozornošću, dok su istovremeno suočeni sa zbunjujućim i velikim skupom često suprotnih informacija, što ih ometa da se fokusiraju samo na glavne informacije.

Istovremeno im treba vremena (zbog smanjene mogućnosti procesiranja informacija) da interpretiraju nove informacije, čak i kad su pouzdane, što može dovesti do pristranosti u rasuđivanju i odlučivanju.

Kahneman i Tversky smatraju se ocima bihevioralne ekonomije/financija. Od njihove suradnje 1969. godine, objavili su preko dvjesto znanstvenih radova, od kojih se većina odnosi na psihološke koncepte s implikacijama u bihevioralnim financijama (Brajković i Radman Peša, 2015, str. 71).

Prema Uzar i Akkaya (2013), kako je navedeno u radu Brajković i Radman Peša (2015), ključne razlike tradicionalnih financija i bihevioralnih financija su sljedeće:

1. Tradicionalne financije pretpostavljaju da ljudi procesuiraju podatke točno i prigodno. Suprotno tome, bihevioralne financije prepoznaju pravilo palca, tj. heuristiku, kako bi procesuirali podatke, što uključuje predrasude u njihovim vjerovanjima i navodi ih na pogreške.
2. Tradicionalne financije pretpostavljaju da ljudi donose sve odluke na transparentan i objektivan način. Suprotno tome, bihevioralne financije smatraju da na rizik i povrate snažno utječe uokvirivanje problema kod donošenja odluke.
3. Tradicionalne financije pretpostavljaju da se ljudi vode razumom i logikom te samostalnom procjenom, dok bihevioralne financije prepoznaju važnost emocija i uzimaju u obzir da su ljudi skloniji pratiti skupinu (psihologija mase) te da to ima značajan utjecaj na donošenje odluka.
4. Tradicionalne financije navode da su tržišta efikasna te da je cijena svake vrijednosnice nepristrana procjena njezine stvarne vrijednosti. Bihevioralne financije, s druge strane, tvrde da heuristika (predrasude, efekti emocija i društvenog utjecaja) često vode do raskoraka u tržišnim cijenama i osnovnim vrijednostima.

Danas bihevioralne financije svoje mjesto nalaze u većini obrazovnih institucija. Prema Schinkusu (2011), ovo je polje istraživanja postalo alternativom neoklasičnim financijama koje su „antibihevioralne“ jer se odnose na teorijski svijet u kojem se ljudi vide kao savršeni alati bez psihologije, dok je financijska stvarnost mnogo kompleksnija od toga.

Primjerice, Dan Ariely (Ariely i dr., 2016, str. 56-57) proveo je eksperiment na Aljasci u suradnji s kreditnim i neprofitnim institucijama. Cilj eksperimenta bio je potaknuti osobe nižeg imovinskog stanja na štednju. Kontrolnoj je

skupini postavljeno pitanje o tome koliko novaca planiraju odvojiti za štednju nakon što su dobili ček s povratom poreza. Eksperimentalnoj skupini pitanje je postavljeno prije nego što su uopće dobili ček s povratom poreza i pitanje je glasil: „Vjerojatno ćete dobiti povrat poreza. Koliki postotak iznosa želite odvojiti za štednju?“ Kontrolna skupina odgovorila je 10 %, a eksperimentalna 15 %. Stvarno odvojeni iznos nakon primitka čeka kod kontrolne skupine bio je 12 %, a kod eksperimentalne gotovo dvostruko više – 22 %. Preinaka pitanja i vremena slanja povećala je štednju građana.

6. POREZNA DISCIPLINA I BIHEVIORALNO OPOREZIVANJE

Povećanje porezne discipline ključna je sastavnica djelotvornog prikupljanja poreznih prihoda. Porezna tijela razvijaju nove pristupe kako bi se povećalo dobrovoljno izvršavanje poreznih obveza, suzbilo neizvršavanje, smanjili troškovi izvršavanja i povećalo sveukupno povjerenje u porezni sustav.

Potpora se može ostvariti u vidu:

- poboljšanja upravljanja rizicima porezne discipline
- uspostavljanja programa za suradnju pri izvršavanju obveza
- poticanja provedbe bihevioralnih pristupa oporezivanju
- osmišljavanja komunikacijskih i informativnih kampanja (Europska komisija, 2023).

Primjerice, Komisija podupire Belgiju u pilot-fazi programa kooperativnog izvršavanja poreznih obveza. Cilj je poboljšati dobrovoljno ispunjavanje poreznih obveza i stvoriti održivi okvir za učinkovito prikupljanje poreznih prihoda. Provedba Programa usklađivanja s poreznom obvezom podržana je prilagođenom stručnom podrškom u:

- izgradnji novih odnosa s velikim poreznim obveznicima, posebno jačanjem odnosa s poreznom administracijom i podizanjem svijesti među poreznim obveznicima
- provedbi okvira porezne kontrole i povezanih tehnika kooperativne procjene usklađenosti s izvršavanjem porezne obveze
- razmjena dobrih praksi i iskustava o usklađenosti suradnje porezne administracije s poreznim obveznicima, sa stručnjacima drugih država članica EU-a iz specijaliziranih jedinica porezne administracije i akademske zajednice (Europska komisija, 2019).

„Bihevioralno oporezivanje razvilo se iz psihološke analize ekonomskog ponašanja. Među prvima ga je izučavao George Katona, koji je prepoznao važnost kombiniranja psihologije, ekonomije. Katona naglašava da su psihološki čimbenici i tradicionalni ekonomski čimbenici isprepleteni u jednom jedinstvenom obrascu te se moraju proučavati zajedno kako bi se razumjelo ekonomsko ponašanje“ (Torgler, 2021, navedeno u Katona, 1947).

Prema Torgleru (2021), jedini drugi način utvrđivanja prave slike o poreznim sklonostima ljudi (osim procjene izvršenja poreznih obveza) jest mjerenje stupnja neizvršavanja porezne obveze ili poreznog otpora. Postoje određeni odnosi između čovjekove orijentiranosti prema zajednici, velikodušnosti u obiteljskim, klupskim ili društvenim pitanjima, razumijevanju i suradnji s javnopravnim tijelima i osobne spremnosti da se podredi bolnim zajedničkim obvezama slične prirode, kao što je plaćanje poreza (Schmölders, 1959, str. 342).

Schmölders je proveo međunarodna komparativna istraživanja s fokusom na Europu, zaključivši da se prema poreznim obveznicima treba odnositi s velikim oprezom i poštovanjem ako porezna administracija želi održati visok porezni moral ili ako želi smanjiti troškove ispunjavanja poreznih obveza, što je usko povezano s Wagnеровим porezno-tehničkim načelima.

Burkhard Strümpel (1969) također je igrao vrlo važnu ulogu u razvoju bihevioralnog oporezivanja i ekonomske psihologije tijekom 70-ih i 80-ih godina 20. stoljeća, baveći se pionirskim radom u drugim područjima, kao što su subjektivno blagostanje ili radne vrijednosti; on je „suočio tradicionalni pristup s empirijskim podacima“ (Torgler, 2021, str. 3).

Prema Torgleru (2021, str. 3-4) „od tada [je] prošlo mnogo vremena u smislu napretka kad je pitanju proučavanje bihevioralnog oporezivanja. Bihevioralno oporezivanje je polje u razvoju koje primjenjuje velik broj metoda poput anketa, laboratorijskih pokusa, terenskih pokusa ili prirodnih eksperimenata. Tijekom svog razvoja zadržalo je visoku razinu interdisciplinarnog angažmana, gdje znanstvenici iz različitih područja znanosti ne samo da pridonose unapređenju znanja nego mogu i bez većih napora (u odnosu na druga znanstvena polja) surađivati. Poteškoće u dobivanju pouzdanih podataka iz polja poreznog prava (npr. u području porezne evazije) zahtijevalo je od znanstvenika da budu maštoviti i otvoreni za primjenu različitih, već navedenih, mogućih metoda (npr. rana uporaba laboratorijskih eksperimenata tijekom 80-ih godina 20. stoljeća), koje su također pomogle interdisciplinarnosti. Za razliku od drugih područja – koja teže specijalizaciji i postaju sve uža kako napreduju istraživanja

– bihevioralno oporezivanje prihvatilo je činjenicu da svaka metoda ima svoje prednosti i nedostatke. Također, složenost same teme zahtijeva od znanstvenika da priznaju da se može mnogo naučiti iz drugih područja kada se napreduje ili kod sintetiziranja raspoloživog znanja.“

Stoga se Alm i Torgler u svom istraživanju iz 2011. godine „pozivaju na tri paradigme koje treba razmotriti, ističući da ispunjavanje poreznih obveza nije vođeno ‘paradigmom kažnjavanja’, koja se oslanja na otkrivanje i kažnjavanje, odnosno da obveza plaćanja poreza nije dio kaznenog prava, već financijskog, konkretno poreznog prava. Iz tog se razloga treba bazirati na paradigme ‘usluge’ i ‘povjerenja’ koje naglašavaju važnost boljeg pružanja usluga poreznim obveznicima od strane porezne administracije“ (Alm i Torgler, 2011, navedeno u Torgler, 2021, str. 4). Najbolji način kako utjecati na ponašanje poreznih obveznika i osvijestiti građane da plaćanje poreza nije mjera kaznenog, nego poreznog prava jest upravo putem poreznog opismenijavanja.

Kirchler, Hoelzl i Wahl (2008) smatraju da pristup *slippery slope* pretpostavlja dva načina za ispunjavanje poreznih obveza: s jedne strane, odvrćanje poreznih obveznika od porezne evazije putem revizije i kazni (što je automatska asocijacija na kazneno pravo) te izgradnju odnosa povjerenja između porezne administracije i poreznih obveznika, s druge strane, o čemu će više govora biti u daljnjim poglavljima.

7. POREZNA PISMENOST I PONAŠANJE POREZNIH OBVEZNIKA

Kao kanale za poboljšanje porezne pismenosti može se navesti, prije svega, poreznu upravu kao državnu instituciju koja ima aktivnu ulogu u informiranju i obrazovanju poreznih obveznika. Zatim, kao jedan od iznimno važnih utjecaja mogu se navesti i obrazovne institucije u smislu formalnog obrazovanja (Šimurina i dr., 2018, str. 9-10), koje u smislu financijske i porezne pismenosti može zaživjeti već od osnovne škole. Putem formalnog obrazovanja porezni obveznici mogu steći porezno znanje i vještine te snalaženje u džungli poreznih propisa koji mogu pozitivno utjecati na stav oko plaćanja poreza. Veliku ulogu igraju i različite neprofitne organizacije i udruge, kao i financijska industrija, ali i mediji koji u suradnji s državnim institucijama imaju moć oblikovanja stajališta kod poreznih obveznika. Pozitivan primjer jest korjenita porezna reforma provedena u Slovačkoj. Kampanja koja je započela prije provođenja

same reforme približila je reformu javnosti te možda čak i pomogla pri smanjenju otpora promjenama koje su bile na vidiku. U ranoj fazi osmišljavanja same reforme, slovačka se vlada obratila predstavnicima poreznih obveznika i privatnog sektora, raznim nevladinim organizacijama te prominentnim stručnjacima iz polja poreznog prava kako bi postigla konsenzus o ciljevima koji se reformom žele postići te kako bi na najbolji način specificirali karakteristike reforme i umanjili fiskalni udar na porezne obveznike. Vlada je to učinila na transparentan način omogućujući i zagovarateljima i protivnicima reforme da iskažu svoje mišljenje na nizu zajedničkih seminara i radionica. Javnosti je dan pristup relevantnim informacijama putem medija (novine, televizija, posebna stranica na internetu) te je tako ostvaren veći stupanj potpore i od poreznih obveznika i od poslovne zajednice.

Ne postoji jednostavan odgovor ni na pitanje što utječe na ponašanje poreznih obveznika prilikom ispunjenja porezne obveze. Važno je shvatiti da pojedini porezni obveznik reagira različito ovisno od situacije do situacije i da postoji niz čimbenika koji oblikuju njegovo porezno ponašanje, a na koje on ponekad ne može utjecati. Upravo je zato važno prepoznati što utječe na stvaranje otpora kod poreznog obveznika jer liječenje simptoma može utjecati samo na konkretnu osobu – pojedinog poreznog obveznika, a ne i na društvo u cjelini. Također, pojedincu poreznom obvezniku može biti neugodno na pozornosti koju je izazvao svojim ponašanjem i pokušajima utjecanja na isto te može doći do kontraefekta u smislu povećanja otpora prilikom ispunjenja porezne obveze koje posljedično može dovesti i do porezne evazije.

Zato je od velike važnosti odabir odgovarajuće strategije koja može dovesti do razlike u stvaranju kratkotrajnog otpora plaćanju porezu ili stvaranju dugoročnog, duboko ukorijenjenog otpora (OECD, 2004, str. 42).

Ne treba automatski pretpostaviti da ciljani porezni obveznici mogu promijeniti ponašanje sami po sebi. To je dodatan razlog zašto porezna administracija mora razumjeti gdje leži uzrok problema u ponašanju. Na primjer, ponašanje ciljanih poreznih obveznika može biti da porezne prijave redovito podnose sa zakašnjenjem. Analizom se može utvrditi da je uzrok u činjenici da od strane trećih osoba nisu na vrijeme primili informacije potrebne za ispunjavanje porezne prijave (npr. pojedinosti o raspodjeli dividendi, polici životnog osiguranja, polici zdravstvenog osiguranja). U ovoj situaciji, kažnjavanje ciljane populacije za njihovo ponašanje neće popraviti temeljni problem. Učinkovitija strategija bila bi raditi s pružateljima potrebnih informacija kako bi poboljšali pravodobnost distribucije informacija.

7.1. RAZUMIJEVANJE UTJECAJA PONAŠANJA POREZNIH OBVEZNIKA

Istraživačka literatura identificira dva široka pristupa problemu ispunjavanja porezne obveze. Prvi proizlazi iz perspektive ekonomske racionalnosti i razvija se ekonomskim i pravnim analizama. Drugi se tiče širih bihevioralnih pitanja i uvelike se oslanja na koncepte i istraživanja iz disciplina kao što su psihologija i sociologija. Ekonomski i bihevioralni pristupi ponekad su u koliziji. Međutim, svaki može biti vrijedan u smislu razumijevanja motivacije i ponašanja poreznih obveznika i postavlja se pitanje kako bi se ta dva pristupa mogla upotrijebiti za međusobno jačane (James i dr., 2001, str. 158-164).

Mnoge zemlje OECD-a uložile su sredstva u istraživanje kako bi pomogle u razumijevanju koji čimbenici utječu na ponašanje poreznih obveznika. Pritom se najviše izdvajaju dvije vrste čimbenika: ekonomski i bihevioralni koji su kroz interdisciplinarnost teme isprepleteni.

Porezni obveznici, prema Weber, Fooken, i Herrmann (2014, str. 11), mogu izabrati siguran put (istinito prijavljivanje prihoda i plaćanje cjelokupne porezne obveze) ili mogu riskirati (utaja poreza potpunim ili djelomičnim neprijavlivanjem prihoda).

Bihevioralni ekonomski čimbenici mogu značajno utjecati na ispunjavanje poreznih obveza, te ako se dobro primjenjuju, obično uzrokuju povećanje ispunjavanja poreznih obveza. Međutim, čini se da ne postoji ujednačen pristup koji se koristi uvidima iz bihevioralne ekonomije, a koji bi odgovarao svima jednako (Weber, Fooken, i Herrmann, 2014, str. 31).

Ekonomске čimbenike čine:

- **financijsko opterećenje** – pretpostavka je da postoji povezanost između iznosa dugovanog poreza i ponašanja vezanog uz ispunjavanje porezne obveze. Primjerice, ako vlasnik tvrtke ima poreznu obvezu koja se može lako platiti, spreman je udovoljiti uz minimalno pružanje otpora. Međutim, ako je porezna obveza značajnijeg iznosa te potencijalno prijeti održivosti poslovanja, vlasnik može pokušati izbjeći plaćanje poreza u cijelosti ili djelomično.
- **trošak izvršavanja porezne obveze** – porezni se obveznici susreću s nizom uobičajenih troškova pri ispunjavanju svojih poreznih obveza koji ponekad premašuju iznos samog poreznog duga. To uključuje vrijeme potrebno za popunjavanje zahtjeva, obrazaca, porezne prijave i sl., trošak vođenja knjigovodstva i neizravne troškove povezane sa složenošću

poreznog zakonodavstva. Uključeni mogu biti i tzv. psihološki troškovi, kao što je stres koji proizlazi iz činjenice da porezni obveznici nisu dovoljno financijski (porezno) pismeni te se ne snalaze u razumijevanju poreznih propisa. Nadalje, mala poduzeća često izražavaju ogorčenost zbog toga što su „neplaćeni poreznici/inkasatori“ zbog svoje uloge u prikupljanju i plaćanju neizravnih i izravnih poreza.

- destimulansi – istraživanja o tome koliki utjecaj imaju sredstva zastrašivanja poreznih obveznika, kao što su financijske kazne i prijetnje kaznenim progonom(ima), sugeriraju da ta metoda ima vremenski ograničen učinak na ponašanje poreznih obveznika u pogledu ispunjavanja porezne obveze. Međutim, istraživanja pokazuju da porezni obveznici koji redovito podmiruju svoju poreznu obvezu smatraju da porezni obveznici koji to ne čine trebaju biti adekvatno kažnjeni.
- poticaji – davanje poticaja poreznim obveznicima može imati pozitivan učinak na njihovo ponašanje u smislu da postaju kooperativniji, iako to treba dodatno istražiti (OECD, 2004, str. 37).

U bihevioralne čimbenike mogu se svrstati:

- individualne razlike – dok mnogi porezni obveznici ispunjavaju svoje porezne obveze, neki to ne čine. Individualni čimbenici koji utječu na ponašanje uključuju spol, dob, razinu obrazovanja, moralni kompas, djelatnost, osobnost, okolnosti i osobna procjena rizika.
- percipirana nejednakost – porezni obveznici koji vjeruju da je „sustav“ nepravedan ili koji imaju negativna osobna iskustva s „nepravednim“ postupanjem prilikom podmirenja porezne obveze manje je vjerojatno da će biti kooperativni
- percepcija minimalnog rizika – ako porezni obveznik ima mogućnost nepodmirivanja porezne obveze i smatra da postoji samo minimalan rizik da bude otkriven, sklon je preuzeti taj rizik. Ovo vjerojatno objašnjava potpunu i djelomičnu poreznu utaju (npr. rad na crno) kao vrstu nezakonite evazije.
- preuzimanje rizika – neki ljudi na izbjegavanje porezne obveze gledaju kao na igru koju treba igrati i osvojiti: vole iskušavati svoju vještinu u izbjegavanju svojih obaveza i izbjegavati biti uhvaćeni (OECD, 2004, str. 37-38).

U svom istraživanju Hofmann i dr. (2017, str. 63-71) dolaze do zaključka da na ispunjavanje porezne obveze u stanovitoj mjeri utječu i sociodemografske kategorije poput dobi, spola, obrazovanja, kao i razine dohotka. Istraživanje je pokazalo da su najznačajnije kategorije dob i spol poreznih obveznika. Rezultati dodatno pokazuju da značajke prikupljanja podataka, kao što je regija u kojoj su podaci prikupljeni, utječu na korelaciju između sociodemografskih značajki i ispunjavanja porezne obveze uzimajući u obzir kulturološke razlike kao važan čimbenik. Konkretno, dob i spol u većoj mjeri, a u manjoj mjeri obrazovanje i razina dohotka, razlikovali su se u odnosu na ispunjavanje poreznih obveza po regijama. Dok su u nekim zemljama sjeverne hemisfere (zapadna Europa, istočna Europa i središnja Azija, Sjeverna Amerika) dob, spol i visina dohotka jači pokazatelji ispunjavanja poreznih obveza, u nekim zemljama južne hemisfere (istočna Azija i Pacifik, subsaharska Afrika, Latinska Amerika i Karibi) dob, spol i visina dohotka prilično su slabi pokazatelji ispunjenja porezne obveze. Što se obrazovanja tiče, nema velike razlike između regija, samo Oceanija odstupa od ukupnog negativne korelacije obrazovanja i ispunjavanja porezne obveze.

7.2. RAZLOZI NEPODMIRIVANJA POREZNE OBVEZE

Prema ekonomskom psihologu Paulu Webleyju (2004), glavni razlozi nepodmirivanja porezne obveze mogu se kategorizirati kao:

- jednakost i pravednost – percipirana pravednost poreznog sustava je važna. Upravo iz tog razloga u ustavima mnogih država uvrštena je odredba koja se odnosi na pravednost i jednakost poreznih sustava. Konkretno u članku 52. Ustava Republike Hrvatske propisano je da svatko dužan sudjelovati u podmirivanju javnih troškova u skladu sa svojim gospodarskim mogućnostima (što je 1. kanon Adama Smitha, koji datira još iz 1776. godine, i knjige Bogatstvo naroda) te da se porezni sustav temelji na načelima pravednosti i jednakosti. Problem je u činjenici da su pravednost i jednakost apstraktni pojmovi koji nemaju konkretnu definiciju i čije značenje „izmiče“ te se razlikuje od osobe do osobe, od mentaliteta do mentaliteta, od podneblja do podneblja. Pa tako na ponašanje poreznog obveznika utječu dva viđenja – da ih sustav tretira nepravedno u odnosu na druge te da su vladajući neproduktivni s poreznim prihodima koje prikupe. Prema jednoj od teorija koja opravdava poreze, osnovni zadatak države jest da neprestano radi reprodukciju porezne snage koja mora postajati sve veća i veća. Iznos ubran porezom treba utrošiti na zadatke i

mjere koji će dovesti do većeg BDP-a, što će dovesti do povećanja osobnih dohodaka poreznih obveznika, što neminovno vodi k povećanju poreza. Da bi oporezivanje pozitivno utjecalo na povećanje BDP-a i dohodaka, potrebno je utrošiti iznos ubran oporezivanjem u produktivne svrhe.

- prilika za neispunjavanje porezne obveze – kao i kod percepcije minimalnog rizika, ako porezni obveznici, u skladu sa svojim poreznim moralom, uoče priliku koja im se pruža, vjerojatno će je iskoristiti. Međutim, nameće se pitanje traže li takvi porezni obveznici svjesno poslove gdje im se pruža takva prilika ili će je iskoristiti ako im se spontano ukaže.
- individualne razlike – oni koji se ne pridržavaju obično su muški, mlađi, egoistični te imaju pozitivan stav prema utaji poreza i negativan stav prema poreznoj vlasti. Postoje dokazi koji upućuju na to da obrazovanje o poreznom sustavu izravno utječe na smanjenje sklonosti prema izbjegavanju plaćanja porezne obveze.
- norme društvenog ponašanja – ako osoba vjeruje da je neplaćanje poreza široko rasprostranjeno, vjerojatnije je da će i sama usvojiti takav obrazac ponašanja
- nezadovoljstvo radom porezne administracije – postoji povezanost između izbjegavanja plaćanja porezne obveze i uvjerenja poreznih obveznika da je porezna administracija neučinkovita, neobrazovana i sklona šikaniranju poreznih obveznika

7.3. IZBJEGAVANJE PLAĆANJA POREZA I VAŽNOST POREZNE PISMENOSTI I POREZNOG PONAŠANJA

Kako je već spomenuto, plaćanjem poreza smanjuje se obveznikova ekonomska snaga, a potencijalno i društveni položaj te se ugrožavaju njegova ljudska prava, kako to porezni obveznik subjektivno smatra. Ti nepovoljni učinci razlog su nastanka otpora kod poreznog obveznika koji, u konačnici, dovodi do djelomičnog ili potpunog izbjegavanja plaćanja poreza.

Izbjegavanje ovisi o mnogim čimbenicima: obrazovnoj strukturi stanovništva, discipliniranosti obveznika u izvršavanju građanskih dužnosti, sankcijama protiv neizvršavanja obveza, stručnosti poreznih organa, efikasnoj kontroli ubiranja, svijesti o pripadanju nekoj društvenoj zajednici, poreznom moralu itd. (Jelčić i dr., 2008, str. 217). Teoretski modeli potrošnje kratko i jasno poka-

zuju da se podmirivanje porezne obveze smanjuje s rastom inflacije, s padom tekućeg dohotka i s očekivanjem većeg dohotka u budućnosti (Madžarević-Šuster, 2002, str. 119).

Kako je u prirodi svakog čovjeka utkana težnja za ostvarivanjem željenih i zacrtanih ciljeva (koji su redovito povezani s materijalnom dobom), jasno je da novčana obveza prema državi, koja uključuje oduzimanje dijela ekonomske snage, neće naići na odobrenje poreznih obveznika, a, u konačnici, ni na ispunjenje od strane svih (Šimović i dr., 2007, str. 593).

Pod utjecajem financijske, odnosno porezne pismenosti porezni obveznici formiraju svoje ponašanje. Razvijanje poreznog znanja kod pojedinaca jedan je od osnovnih preduvjeta potrebnih za stvaranje visokog poreznog morala, pri čemu su u tom segmentu obrazovaniji porezni obveznici bolji, odgovorniji i aktivniji porezni obveznici ako se, naravno, prikupljeni porezni prihodi produktivno utroše.

Velika je korelacija između poreznog morala i poreznog ponašanja i porezne pismenosti pojedinaca. Ponašanje poreznog obveznika jest način na koji pojedinac postupa u vezi s obvezom plaćanja poreza, a moguće ga je podijeliti u dvije osnovne kategorije:

- plaćanje poreza koje može biti dobrovoljno i prisilno
- izbjegavanje plaćanja poreza koje može biti zakonito i nezakonito (Šimurina i dr., 2018, str. 6).

Ponašanje poreznih obveznika podložno je utjecaju mnogobrojnih čimbenika koji se mogu svrstati u četiri osnovne kategorije:

1. ekonomski čimbenici koji određuju stanje u ekonomiji, poput stope inflacije, zaposlenosti, siromaštva i sl.
2. politički čimbenici koji podrazumijevaju stabilnost vlade, korumpiranost državnih dužnosnika, kredibilitet vlade i općenito političkih stranaka
3. sociološki čimbenici koji uključuju varijable poput mentaliteta društva, društvenih normi
4. psihološki čimbenici poput optimizma, lokusa kontrole, sklonosti preuzimanja rizika (Šimurina i dr., 2018, str. 7).

Kombinacija navedenih čimbenika koji kreću od samog pojedinca pa se prelijevaju na društvo u cjelini zapravo čini da financijska pismenost iz koje proizlazi konkretno porezna pismenost izravno može utjecati na bolje ponašanje poreznih

obveznika koji su skloniji podmirivanju svoje porezne obveze uz minimalan otpor. Cilj je porezne pismenosti povećati svijest poreznih obveznika o poreznim pitanjima, ali i poreznom riziku. Porezni rizik zapravo predstavlja opasnost od promjene poreznih propisa koji se mogu nepovoljno odraziti na financijsku situaciju pojedinca, povećavajući njegove izdatke, te utječu na smanjenje atraktivnosti ulaganja u pojedine oblike imovine (Šimurina i dr., 2018, str. 15). Međutim, problem je kod svih zemalja u svijetu činjenica da je porezni sustav podložan stalnim i velikim promjenama. Koliko god je težnja idealan, odnosno racionalan porezni sustav, u stvarnosti se radi o poreznim sustavim koji su kaotični. Porezni sustav svake zemlje jest zapravo iznimno složen mehanizam, koji je podložan stalnim i čestim promjenama u vidu manjih poreznih reformi, ali i korjenitih poreznih reformi u vidu uvođenja novih poreza, manipuliranja poreznim stopama, sužavanjem ili proširivanjem poreznih oslobođenja, sužavanjem ili proširivanjem porezne osnovice, ukidanjem određenih poreznih oblika, uvođenjem izvanrednih poreza i sl., što sam porezni sustav čini izrazito zahtjevnim. Upravo ta složenost i česte promjene predstavljaju problem poreznim obveznicima u snalaženju, posebice onima koji su niskog stupnja porezne pismenosti. Posljedično, negativne su posljedice na ponašanje poreznih obveznika koje rezultira stannovitim otporom prilikom plaćanja porezne obveze. Porezni obveznici, kao pasivni porezni subjekti, percipiraju plaćanje poreza kao napad na svoju privatnost, na svoj osobni život. Činjenica da su porezi derivativni fiskalni prihod, odnosno da se na temelju fiskalnog suvereniteta države izvode iz porezne sposobnosti i snage poreznog obveznika, da su prinudni i da se plaćanjem smanjuje imovina poreznog obveznika, kod njih se stvara izrazito visok stupanj otpora. Iz tog su razloga mnogi pravnici, ekonomisti, sociolozi, filozofi, pa čak i teolozi pokušali naći opravdanje za postojanje i prinudnost plaćanja poreza.

Analiza globalnih rezultata naglašava da socioekonomski čimbenici pomažu objasniti porezni moral pojedinaca na sljedeći način:

1. Obrazovaniji pojedinci imaju pozitivnije stavove prema plaćanju poreza.
2. Žene imaju veći porezni moral od muškaraca.
3. Manje je vjerojatno da će stariji ljudi opravdati varanje na porezima od mlađih ljudi.
4. Oni koji su državljani zemlje u kojoj žive imaju veći porezni moral od negrađana.
5. Pojedinci koji su vjerski opredijeljeni imaju pozitivniji stav prema plaćanju poreza (OECD Library, 2019).

Neki od tih rezultata možda su očekivani – oni s visokim obrazovanjem, na primjer, vjerojatnije će imati dublje razumijevanje uloge oporezivanja u gospodarstvu. Ipak, potvrđivanje tih veza ima praktičnu vrijednost, dajući povjerenje u upotrebu takvih čimbenika u izradi profila poreznih obveznika i omogućujući bolje usmjeravanje napora za povećanje usklađenosti (Jerković, 2023, str. 384).

Institucionalni čimbenici pokazuju da će vladine politike i uspješnost njihovih provođenja također imati značajan utjecaj na porezni moral:

1. Pojedinci koji vjeruju da žive u meritokratskom društvu imaju znatno veći porezni moral.
2. Oni koji vjeruju svojoj nacionalnoj vladi pokazuju veći porezni moral od onih koji to ne čine.
3. Porezni obveznici koji utvrde da je fiskalna preraspodjela poreznog opterećenja ključna (tj. vlade bi trebale oporezivati bogate kako bi omogućile potporu siromašnima) pokazuju veći porezni moral.
4. Oni koji demokraciju doživljavaju kao najbolji sustav vlasti za svoju zemlju obično misle da je varanje na porezima neopravdano (OECD Library, 2019).

Torgler i Schneider (2009) tvrde da bolje institucije i veća učinkovitost vlade motiviraju pojedince da djeluju zakonito, uključujući poreznu usklađenost. Richardson (2008) u svom istraživanju ističe značajnu povezanost između visoke razine utaje poreza i nižih razina pravne provedbe i povjerenja u vladu. Nadalje, na temelju ispitivanja poreznog morala u 30 europskih zemalja, Frey i Torgler (2007) izvještavaju o pozitivnoj povezanosti institucionalne kvalitete i poreznog morala.

Također, mogu se navesti Brink i Porcano (2016), koji ispituju ulogu poreznog morala u povezanosti nacionalne kulture i utaje poreza. Oni izvještavaju o značajno pozitivnoj povezanosti između individualizma i udaljenosti moći i poreznog morala. Također navode negativnu značajnu povezanost između poreznog morala i utaje poreza. Niže razine poreznog morala primjećuju se u zemljama s višim razinama utaje poreza (Allam, Moussa, Abdelhady i Yamen, 2022).

Velika je vjerojatnost da će pitanje pravednosti igrati ulogu u ispunjavanju poreznih obveza pojedinaca. Kirchler, Hoelzl i Wahl (2008, str. 219) smatraju da pri tome treba razlikovati tri dimenzije: preraspodjelu, postupke i sankcije. Prvo se

odnosi na percipirano porezno opterećenje poreznih obveznika u usporedbi s njima jednakima. Drugi aspekt odnosi se na to kako se porezna administracija odnosi prema poreznim obveznicima. Treće se odnosi na tretman i sankcioniranje prevaranata. Kao još jedan problem javlja se i problem krijumčara (engl. *free riders*), tj. slijepog putnika koji podrazumijeva situaciju u kojoj pojedinac ili skupina pojedinaca ne plaća za korištenje proizvoda i usluga u čijoj potrošnji sudjeluje. Problem krijumčarenja teško je izbjeći jer je povezan s jednom od temeljnih karakteristika javnih dobara i usluga, a to je neisključivost. Javna dobra i usluge nekonkurentni su u potrošnji jer potrošnja jedne osobe ne umanjuje mogućnost potrošnje druge osobe, a neisključiva su utoliko ukoliko znači da je neplatiše, tj. krijumčare nemoguće isključiti iz potrošnje (Šimurina, 2018, str. 11). Prema Freyu i Torgleru (2007), viša institucionalna kvaliteta povezana je s većim ispunjavanjem poreznih obveza. Porezni obveznici mogu biti motivirani platiti svoju pravično utvrđenu poreznu obvezu kako bi financirali učinkovitu vladu. Feld i Frey (2002) te Weber, Fooken, i Herrmann (2014) tvrde da su povjerenje i poštovanje poreznih obveznika povezani s ispunjavanjem poreznih obveza.

Izbjegavanje plaćanja ponekad je rezultat svjesnog nastojanja, tj. namjere poreznog obveznika da netočnim prikazivanjem ili prikrivanjem relevantnih činjenica pred poreznim organima smanji svoju poreznu obvezu (porezni dug), odnosno uopće ne plati porez. U takvim se slučajevima govori o aktivnom izbjegavanju plaćanja poreza i ta je vrsta izbjegavanja plaćanja poreza usko vezana s niskim poreznim moralom (Jelčić i dr., 2008, str. 217).

Osim navedenog, izostanak može biti rezultat i nekih drugih čimbenika: neznanja ili nedovoljne informiranosti poreznih obveznika o njihovoj poreznoj obvezi, neadekvatne organiziranosti, nedovoljne efikasnosti, stručnosti i motiviranosti porezne administracije i nekvalitetnih propisa kojima je regulirana obveza (praznine i nejasnoće u propisima, njihova nepreglednost i sl.). Tada se, pak, radi o pasivnom izbjegavanju plaćanja poreza koje jednostavno može biti rezultat nedostatne financijske i porezne pismenosti prije nego niskog stupnja poreznog morala. Do njega najčešće dolazi pri pojavi novih poreza ili pojedinih poreznih rješenja, ali i kod povremenih ili jednokratnih poreza u slučajevima kada porezni obveznici još nisu točno upoznati sa svojom poreznom obvezom (Jelčić i dr., 2008, str. 218).

Iako se smatra kako svi porezi unose distorziju u gospodarstvo, brojna empirijska istraživanja pokazala su kako ipak postoje značajne razlike između poreznih oblika te da pojedini porezni oblici više štete rastu od drugih. Većina autora,

u ovom kontekstu, prihvaća podjelu iz Kneller, Bleaney i Gemmell (1999, str. 177), koji su porezne oblike podijelili u distorzivne (porez na dohodak uz prateće obvezne doprinose za socijalna davanja, porez na dobit i imovinske poreze) i manje distorzivne (porezi na potrošnju). Smatra se kako se štetnost distorzivnih poreza može smanjiti ako se oni maksimalno pojednostave, što je glavni argument za uvođenje i primjenu proporcionalnog poreza na dohodak i dobit (engl. *flat tax*). Radi se o konceptu oporezivanja dohotka i dobiti po istoj proporcionalnoj stopi, dok se indirektna progresija postiže primjenom osobnog odbitka koji se može uvećati za ostale odbitke, poput uzdržavanih članova obitelji, broja djece ili stupnja invalidnosti kod oporezivanja dohotka. Glavni zagovaratelji ovog pristupa oporezivanju bili su američki ekonomisti Hall i Rabushka (2007), koji su se 80-ih godina 20. stoljeća pozivali na Lafferovu krivulju, po kojoj porastom porezne stope rastu i porezni prihodi. Nakon određene visine porezne stope daljnji porast poreznog opterećenja smanjuje porezne prihode (Šimović i Deskar-Škrbić, 2019), a razlog tome može se naći upravo u izbjegavanju plaćanja poreza najčešće putem sive ekonomije i rada na crno. Upravo iz tog razloga, kao i brojnih drugih vezanih uz poimanje pravednosti, posebice od strane poreznih obveznika, učinkovitost porezne administracije i općenito pojednostavljenje i veću transparentnost poreznog sustava, zalagali su se za oporezivanje dohotka i dobiti proporcionalnom poreznom stopom (engl. *flat tax*).

8. PREPOZNAVANJE UČINKA SAMOG POREZNOG SUSTAVA PUTEM PRIZME POREZNOG ZAKONODAVSTVA I POREZNE ADMINISTRACIJE

Učinkovito podmirivanje porezne obveze od strane poreznih obveznika počinje dobrim poreznim zakonodavstvom. Zakon koji je jasan i nedvosmislen s obzirom na svoju namjeru i tumačenje pruža čvrstu osnovu na temelju kojih se mogu graditi programi kooperativnosti poreznih obveznika s poreznom administracijom. Nejasan, opsežan ili dvosmislen zakon stvara veće mogućnosti da se porezni obveznici okrenu poreznoj evaziji (OECD, 2004, 43).

Na mnogo načina, dobar zakon podupire sposobnost porezne administracije da provede postupak oporezivanja na pravedan način kako od strane države tako i od strane poreznog obveznika jer jedno ne isključuje drugo. Ako zajednica percipira zakon kao nepravedan ili neprikladan prema običajima i praksi zajednice, onda, neizbježno, postoji povećan rizik od porezno nepoželjnog ponašanja. Na primjer, neki porezni obveznici u Velikoj Britaniji odbili su platiti

birački porez ranih 90-ih godina 20. stoljeća smatrajući taj čin moralno ispravnim jer su porez doživljavali kao nepravedan. Konkretno, građani sa sličnim primanjima tretirani su različito s obzirom na određivanje porezne obveze. Nadalje, nezadovoljstvo i otpor porasli su kad je porezno opterećenje poraslo zbog porezne evazije dijela poreznih obveznika (Cullis, Jones, Morrissey, 1993, str. 407-425).

Može se zaključiti da primjena zakona ponekad može imati neželjene posljedice iz perspektive porezne administracije. Zakon je jasan s obzirom na namjeru i primjenu u smislu ekonomsko-političkih poreznih načela izbora poreznog oblika i izbora poreznog izvora, a ipak uzrokuje ponašanje koje ukazuje na aktivno nastojanje zajednice da izbjegne podmirenje porezne obveze koju smatra nepravednom i nepoželjnom.

Porezna uprava s radom počinje primjenom poreznih zakona. Zakon predstavlja polaznu točku od koje porezna administracija djeluje i iz kojeg se, u konačnici, primarno stvara otpor plaćanju poreza. Primjena poreznih zakona uz istovremeno zadržavanje povjerenja poreznih obveznika predstavlja izazov za svaku poreznu administraciju. Tu su i neizostavna porezno-tehnička porezna načela po kojima troškovi porezne administracije prilikom prikupljanja poreza trebaju biti što niži tako da što veći dio prikupljenog novca na ime poreza uđe državni ili lokalni proračun. Primjerice, tijekom 80-ih godina 20. stoljeća u Sjedinjenim Američkim Državama ukupni troškovi prikupljanja federalnog poreza na dohodak/dobit procjenjivali su se na 363 milijarde dolara, odnosno na troškove otpada 65 % novca prikupljenog oporezivanjem (Hall i Rabushka, 2007, str. 10).

9. ZAKLJUČAK

Primarni izvor financiranja javnih potreba putem usluga i dobara predstavljaju porezi. Javne potrebe, kao što su obrazovanje, zdravstvena zaštita, javna uprava, sudstvo, vojska, policija, kultura, administracija itd., izravno ovise o učinkovitom prikupljanju fiskalno najizdašnijih javnih prihoda – poreza.

Pitanje gospodarskoga rasta te ciljeva i učinaka oporezivanja prvenstveno se promatra kroz pitanje učinkovitosti i produktivnosti. U raspravama o tome koliki je utjecaj poreza na učinkovitost polazi se od hipoteze da porezi unose distorziju u gospodarstvo, ali i djeluju na ponašanje fizičkih osoba (kućanstava) i pravnih osoba.

Porezi neminovno utječu na odluke poreznih obveznika (kako fizičkih tako i pravnih osoba) o razini potrošnje, štednji, investicijama te utječu na ponudu rada na tržištu i preuzimanju rizika, na odnos ponude i potražnje, odnosno utječu na stanje na tržištu. To ne bi bio slučaj kada bi porezni sustav bio racionalan, odnosno idealan putem neutralnosti poreza, što je u praksi izrazito teško implementirati. Što je u nekom poreznom sustavu veći broj poreznih oblika, to je on složeniji te je veći broj distorzija, što posljedično dovodi do smanjenja učinkovitosti.

Neovisno o kojem se poreznom obliku radi, ponašanje poreznih obveznika je važno. Želimo da plate porez, i to uz minimalan otpor. Potrebno je osvijestiti porezne obveznike o koristi koju imaju od plaćanju poreza u smislu zadovoljavanja zajedničkih potreba od kojih i oni kao pojedinci i društvo u cjelini imaju koristi. Tu je potrebno shvatiti ulogu vladajućih i porezne administracije. S jedne su strane legitimna vlast (moć), profesionalna vlast (moć) te moć uvjeravanja i prisile od strane središnje države, a s druge povjerenje u institucije i vladajuće od strane građana (poreznih obveznika). Konačnu prevagu u ponašanju poreznih obveznika zapravo donosi kombinacija svih čimbenika. Prije uvođenja poreza potrebno je pomno istražiti što motivira ili demotivira porezne obveznike prilikom plaćanja poreza, pri čemu, prije svega, treba voditi računa o učincima oporezivanja (u smislu prevaljivosti poreza koji se uvodi i u smislu potencijalne porezne evazije) te što više ulagati u obrazovanje porezne administracije i samih poreznih obveznika jer ovdje leži ključ za bolje razumijevanje i uspostavljanje obostranog povjerenja.

Država se treba voditi izrekom *boni pastores tondere oves, non deglubere*, odnosno *dobar pastir striže svoje ovce, ne guli im kožu* u smislu postavljanja granice poreznog opterećenja i na zadovoljstvo same države, ali i na zadovoljstvo poreznih obveznika.

S aspekta države (i jedinica lokalne i regionalne samouprave), osnovno bi geslo trebalo biti da su porezi lako naplativi, ali neizbježni kako u vidu zakonite tako i u vidu nezakonite porezne evaziji. Prije svega, kako bi se lakše utjecalo na pozitivno ponašanje poreznih obveznika u smislu ispunjavanja porezne obveze uz minimalan otpor (kojeg će neminovno uvijek biti), važno je odrediti jasan cilj koji se želi postići oporezivanjem pa je potrebna suradnja između vladajućih, porezne administracije, medija i samih poreznih obveznika.

Vrsta porezne stope također može utjecati na ponašanje poreznog obveznika prema poreznoj obvezi. S aspekta pravednosti kao socijalno-političkog pore-

znog načela, nije svejedno je li u pitanju neprekinuta ili tranširana progresivna porezna stopa ili, pak, proporcionalna porezna stopa, tzv. *flat tax* te se nameću mnoga otvorena pitanja vezana uz ovu problematiku.

S obzirom na poreznu administraciju, potrebno je povezati porezne obveznike s poreznom upravom u smislu ulaganja u povjerenje i profesionalnost, što utječe na volju poreznog obveznika da surađuje s poreznom upravom i pravovremeno podmiri poreznu obvezu uz minimalan otpor.

Na kraju, uključivanje bihevioralnog faktora u poreznu politiku vodi izbjegavanju potencijalno nerealne pretpostavke o ispunjavanju porezne obveze, uz optimalno postizanje i bolju kvalitetu prikupljanja poreza.

REFERENCE

1. Allam, A., Moussa, T., Abdelhady, M. i Yamen, A. (2022) National culture and tax evasion: The role of the institutional environment quality *Journal of International Accounting, Auditing and Taxation*, Vol. 52,100559 <https://www.sciencedirect.com/science/article/pii/S1061951823000381> [Pristup 15. prosinca 2023.]
2. Alm, J. i Torgler, B. (2011) Do ethics matter? Tax compliance and morality. *Journal of Business Ethics*, 101(4), str. 635-651.
3. Ariely, D., Beasley, M., Berman, K., De La Rosa, W., (2016) *Common Cents Lab, End of the year 2016 report*, MetLife Foundation, https://advanced-hindsight.com/archive/wp-content/uploads/2017/02/Common-Cents-Lab-End-Of-Year-Report-2016_Rev-15.pdf [Pristup 5. svibnja 2024.]
4. Barr A. i Serra D. (2010) Corruption and culture: An experimental analysis, *Journal of Public Economics*, Vol. 94, No. 11-12, str. 862-869.
5. Bejaković, P. (2009) Tax evasion, tax capacity and trust in transitional countries: The case of Croatia, *Društvena istraživanja: časopis za opća društvena pitanja*, Vol. 18, No. 4-5 (102-103)
6. Brajković, A. i Radman Peša, A., (2015) Bihevioralne financije i teorija „Crnog labuda“, *Oeconomica Jadertina* 1/2015., <https://hrcak.srce.hr/file/216066>
7. Brink, W. D. i Porcano, T. M., (2016) The impact of culture and economic structure on tax morale and tax evasion: A country-level analysis using SEM. *Advances in Taxation*, 23
8. Cnossen, S. (2006) Alcohol Taxation and Regulation in the European Union, *CESifo Working Paper*, br. 1821
9. Cullis, J., Jones, P. i Morrissey, G. (1993) The charge of the tax brigade: a case study of government failure and tax reforms, *European Journal of Political Economy*, 9, str. 407-425.

10. Weber, T.O., Fookien, J. i Herrmann, B. (2014) *Behavioural Economics and Taxation*, European Commission, *Taxation Papers*, WORKING PAPER N.41
11. Europska komisija, https://reform-support.ec.europa.eu/what-we-do/revenue-administration-and-public-financial-management_hr, [Pristup 29. prosinca 2023.]
12. Europska komisija, (2019) *Implementing cooperative tax compliance in Belgium*, https://reform-support.ec.europa.eu/what-we-do/revenue-administration-and-public-financial-management/implementing-cooperative-tax-compliance-belgium_hr [Pristup 29. prosinca 2023.]
13. Europska komisija, COM 2020, 312 final, Komunikacija Komisije Europskom parlamentu i Vijeću, Bruxelles 2020, *Akcijski plan za pravedno i jednostavno oporezivanje kojim se podupire strategija oporavka*, 10
14. Feld L.P. i Frey B.S. (2002) Trust breeds trust: How taxpayers are treated, *Economics of Governance*, Vol. 3, No. 2, str. 87-99.
15. Frey B.S. i Torgler B. (2007) 'Tax morale and conditional cooperation', *Journal of Comparative Economics*, Vol. 35, No. 1, str. 136-159.
16. Gadžo, S. (2020) *Jačati porezni moral u Hrvatskoj, ali i odgovornost mjerodavnih za trošenje*. Dostupno na: <https://www.glas-koncila.hr/doc-dr-stjepan-gadzomedunarodni-strucnjak-za-oporezivanje-multinacionalnih-tvrtki-jacati-porezni-moralu-hrvatskoj-ali-i-odgovornost-mjerodavnih-za-trosenje>
18. Hall, R. E. i Rabushka, A. (2007) *The Flat Tax, Second Edition*, Hoover Institution Press, Stanford University, Stanford, California
19. Hofmann, E., Voracek, M., Bock, C., Kirchler, E. (2017) Tax compliance across socio-demographic categories: Meta-analyses of survey studies in 111 countries, *Journal of Economic Psychology*, Volume 62
20. Horowitz, M. (2013) *Psihologija ekonomskog ponašanja – priručnik o osnovama bihevioralne ekonomije*, Edunova škola informatike, str. 1-91.
21. James, S., Hasseldine, J., White, P. i Toumi, M. (2001) Developing a Tax Compliance Strategy for Revenue Services, *Bulletin from International Bureau of Fiscal Documentation*, str. 158-164
22. Jelčić, B., Lončarić-Horvat, O., Šimović, J., Arbutina, H. i Mijatović, N. (2008) *Financijsko pravo i financijska znanost*, Narodne novine, Zagreb
23. Jelčić, B. (2001) *Javne financije*, drugo izdanje, RRiF-plus, Zagreb
24. Jerković, E. (2023) Povezanost poreznog morala i porezne evazije, *Zbornik radova Međunarodne naučne konferencije Pravo i društvene vrednosti*, Pravni fakultet u Nišu, Niš, str. 377-400.
25. Jerković, E. (2018) Reducing the tax compliance gap by improving tax administration. *IMR Interdisciplinary Management Research XIV*, the Josip Juraj Strossmayer University of Osijek, Faculty of Economic in Osijek, Croatia, Hochschule Pforzheim University, Osijek
26. Jerković, E. (2017) Važnost ciljeva i socijalno-političkih načela oporezivanja u funkciji ostvarenja pravednosti prilikom oporezivanja dohotka od nesamostalnog rada i sa-

- mostalne djelatnosti, *Third international scientific Conference ERAZ 2017-Knowledge based sustainable economic development*, Faculty of Business Studies, Mediterranean University - Podgorica, Montenegro; 2. University of National and World Economy - Sofia, Bulgaria; 3. Faculty of Commercial and Business Studies - Celje, Slovenia; 4. Faculty of Applied Management, Economics and Finance – Belgrade; Serbia 5. Association of Economists and Managers of the Balkans - Belgrade, Serbia Beograd, str. 217.-230.
27. Kapor, P. (2014) Bihevioralne finansije, *Megatrend revija*, 11(2), str. 73–94.
 28. Katona, G. (1947) Contribution of psychological data to economic analysis. *Journal of the American Statistical Association*, 42(239), str. 449-459.
 29. Kirchler E. (2007) *The Economic Psychology of Tax Behaviour*. Cambridge University Press; 2007:i-iv.
 30. Kirchler E., Hoelzl E. i Wahl I. (2008) Enforced versus voluntary tax compliance: The “slippery slope” framework, *Journal of Economic Psychology*, Vol. 29, No. 2, str. 210-225.
 31. Kneller, R., Bleaney, M. i Gemmel, N. (1999) Fiscal policy and growth: evidence from OECD countries, *Journal of Public Economics*, 1999, vol. 74, issue 2, 171-190
 32. Kountouris, Y. i Remoundou, K (2013) Is there a cultural component in tax morale? Evidence from immigrants in Europe, *Journal of Economic Behavior & Organization*, 96/2013
 33. London Economics (2010) *Study analysing possible changes in the minimum rates and structures of excise duties on alcoholic beverages*, Final Report to EC DG Taxation and Customs Union.
 34. Madžarević-Šujster, S. (2002) Procjena porezne evazije u Hrvatskoj, *Financijska teorija i praksa*, Vol. 26, No. 1
 35. Mahović-Komljenović, M., (2009) Informacijski sustav i porezna evazija – uloga menadžera podataka, *Zbornik Ekonomskog fakulteta u Zagrebu*, Vol. 7, No. 1
 36. Mann, F.K. (1937) *Steuerpolitische Ideale*, Jena
 37. OECD, (2004) *Compliance Risk Management: Managing and Improving Tax Compliance* <https://www.oecd.org/tax/administration/33818656.pdf> [Pristup 25. studenoga 2023.]
 38. OECDiLibrary, (2019) *Tax Morale, What Drives People and Businesses to Pay Tax?* <https://www.oecd-ilibrary.org/sites/552896d8-en/index.html?itemId=/content/component/552896d8-en> [Pristup 25. studenoga 2023.]
 39. Park, H. i Sohn, W. (2013) Behavioral Finance: A Survey of the Literature and Recent Development, *Seoul Journal of Business*, 9(1), str. 3–42.
 40. Rabinovich, L., Brutscher, P.B., De Vries, H., Tiessen, J., Clift, J. i Reding, A. (2012) *Further study on the affordability of alcoholic beverages in the EU*, Bruxelles: European Commission
 41. Richardson, G. (2008) The relationship between culture and tax evasion across countries: Additional evidence and extensions, *Journal of International Accounting, Auditing and Taxation*, 17 (2)

42. Schinckus, C. (2011) Archeology of Behavioral Finance, *IUP Journal of Behavioral Finance*, 8(2), str. 7–22.
43. Schmolders, G. (1959) Fiscal psychology: A new branch of public finance, *National Tax Journal*, 12(4), str. 340–345.
44. Schmolders, G. (1960) *Das Irrationale in der öffentlichen Finanzwirtschaft*. Frankfurt am Main, D: Suhrkamp
45. Sindikat grafičara i medija, Porezni nemoral u doba korone – Zar je novac važniji od ljudskog života? <https://www.sгим.hr/porezni-nemoral-u-doba-korone-zar-je-novac-vazniji-od-ljudskog-zivota/1997/>. [Pristup 30. studenoga 2023.]
46. Smith, S. (2005) Economic Issues in Alcohol taxation u: S. Cnossen, ur. *Theory and Practice of Excise Taxation*, 56–83. New York: Oxford University Press Inc.
47. Sopek, P. (2013) Sustav oporezivanja alkohola u Europskoj uniji i Hrvatskoj, Institut za javne financije, Newsletter, Povremeno glasilo Instituta za javne financije, br. 76/2013
48. Strümpel, B. (1969) The Contribution of Survey Research to Public Finance, in: A. T. Peacock (ed.), *Quantitative Analysis in Public Finance*. Praeger Press, str. 14–32.
49. Šimović, H., Deskar-Škrbić, M. (2019) *Teorija i politika oporezivanja (II dio)*, EJS 11, <https://arhivanalitika.hr/blog/ejs-11-teorija-i-politika-oporezivanja-ii-dio/> [Pristup: 1. prosinca 2023.]
50. Šimović, J., Rogić-Lugarić, T. i Cindori, S. (2007) Utaja poreza u Republici Hrvatskoj i mjere za njezino sprječavanje, *Hrvatski ljetopis za kazneno pravo i praksu*, Vol. 14, broj 2
51. Šimurina, N., Dražić Lutitsky, I., Barbić, D. i Dragija Kostić, M. (2018) *Osnove porezne pismenosti*. Narodne novine, Zagreb
52. Torgler, B., (2021) *Behavioral Taxation: Opportunities and Challenges*, Center for Research in Economics, Management and the Arts, Working Paper No. 2021-25, Zürich
53. Torgler, B. i Schneider, F., (2009) The impact of tax morale and institutional quality on the shadow economy. *Journal of Economic Psychology*, 30 (2)
54. Ustav RH, Narodne novine br. 56/90, 135/97, 08/98, 113/00, 124/00, 28/01, 41/01, 55/01, 76/10, 85/10, 05/14
55. Uzar, C. i Akkaya, G. (2013) The Mental and Behavioral Mistakes Investors Make, *International Journal of Business and Management Studies*, 5(1), str. 120–128.
56. Vučković, S. (2010) Biheviorističke finansije i finansijski menadžment, *Ekonomске teme* br. 48, str. 629–640.
57. Weber, R.(2005) Behavioral economics, *The handbook of economic sociology*, str. 91–108
58. Webley, P. (2004) Tax Compliance by businesses, *New Perspectives on Economic Crime*, edited Sjögren, Hans i Skögh, Goran Edward Elgar, Cheltenham

BEHAVIORIST KNOWLEDGE IN TAX POLICY⁷**Full Professor Renata Perić, PhD**

J. J. Strossmayer University of Osijek, Faculty of Law Osijek
e-mail: rperic@pravos.hr

Associate Professor Emina Jerković, PhD

J. J. Strossmayer University of Osijek, Faculty of Law Osijek
e-mail: ekonjic@pravos.hr

ABSTRACT

The paper will discuss an increasingly important topic: the concept of behavioural taxation. The purpose is to highlight the significance of this relatively new concept in taxation, which aims not only to achieve the primary fiscal goal of taxation but also to address taxpayer dissatisfaction related to fulfilling inevitable tax obligations. Embedded within behavioural taxation is the notion of tax morality, which can be influenced through financial and tax literacy. This, in turn, affects taxpayer behaviour, as individuals inevitably exhibit varying degrees of resistance when meeting tax obligations. The paper employs methods of analysis, comparison, and deduction to explore these themes.

Key words: objectives of taxation, behavioral taxation, tax morality, tax behavior

JEL classification: G41, K34

⁷ This paper is a product of work that has been fully supported by the Faculty of Law Osijek Josip Juraj Strossmayer University of Osijek under the project nr. IP-PRAVOS-21 „Fiscal policy and development of the public finance system”.



Cijena: 0,00 €