


EKONOMSKA POLITIKA HRVATSKE U 2022. - POSTPANDEMIJSKI IZAZOVI



29
tradicionalno
savjetovanje





HRVATSKO DRUŠTVO EKONOMISTA

*EKONOMSKA POLITIKA
HRVATSKE U 2022. -
POSTPANDEMIJSKI IZAZOVI*



29. tradicionalno savjetovanje

Ekonomska politika Hrvatske u 2022.

Postpandemijski izazovi

Nakladnik: Hrvatsko društvo ekonomista, Heinzelova 4a, Zagreb, www.hde.hr
Za Nakladnika: prof. emer. dr. sc. Ljubo Jurčić, predsjednik HDE-a
Sunakladnik: Inženjerski biro d.o.o., Zagreb, www.ingbiro.hr

Programsko-znanstveni odbor Savjetovanja

Predsjednik: prof. emer. dr. sc. Ljubo Jurčić
Članovi: doc. dr. sc. Katarina Bačić
dr. sc. Mladen Mlinarević
izv. prof. dr. sc. Lucija Rogić Dumančić
prof. dr. sc. Josip Tica
prof. dr. sc. Darko Tipurić
prof. dr. sc. Mladen Vedriš

Glavni urednici: prof. dr. sc. Josip Tica
doc. dr. sc. Katarina Bačić

Urednički odbor: doc. dr. sc. Katarina Bačić
izv. prof. dr. sc. Lucija Rogić Dumančić
prof. dr. sc. Josip Tica

Lektorice: Zrinka Mlinarević, MA
Mirna Rudeš, prof.

Grafička urednica: Ana-Marija Perić, dipl. ing.

Tisak: Sveučilišna tiskara d.o.o., Trg Republike Hrvatske 14, 10000 Zagreb

Učestalost izlaženja: jedanput godišnje

Radovi su recenzirani na temelju dvostruke anonimne recenzije.

ISSN 1849-6482



EKONOMSKA POLITIKA HRVATSKE U 2022. - POSTPANDEMIJSKI IZAZOVI

29
tradicionalno
savjetovanje



Sadržaj

Ljubo Jurčić

POSTPANDEMIJSKA EKONOMSKA OČEKIVANJA 1

Ana Lujčić

Lucija Rogić Dumančić

**KOMPARATIVNA ANALIZA MJERA POMOĆI USLIJED
PANDEMIJE COVID-19 U ODABRANIM
ZEMLJAMA ČLANICAMA EU 8**

Željko Bogdan

**KOMPARATIVNA ANALIZA INFLACIJE U POSTCOVID
RAZDOBLJU ZA HRVATSKU I EUROZONU –
MOŽE LI SE OCIJENITI PROBLEMATIČNOM? 37**

Vladimir Čavrak

**GOSPODARSKA REVITALIZACIJA NERAZVIJENOG
PODRUČJA POGOĐENOG POTRESOM
(SLUČAJ SISAČKO-MOSLAVAČKE ŽUPANIJE) 75**

Josip Tica

Viktor Viljevac

UZROCI EKONOMSKOG ZAOSTAJANJA HRVATSKE 122

Domagoj Sajter

**ZNANSTVENI REZULTATI I SURADNJA
AUTORA S EKONOMSKIH FAKULTETA U
OSIJEKU, RIJECI, SPLITU I ZAGREBU 155**

Karla Radić

Vladimir Arčabić

**ČINI LI EUROZONA OPTIMALNO VALUTNO PODRUČJE?
ANALIZA USKLAĐENOSTI POSLOVNIH CIKLUSA 181**

Zvonimira Šverko Grdić

FINANCIRANJE TRANZICIJE NA KRUŽNO GOSPODARSTVO	208

Tomislav Globan

ANALIZA MEĐUODNOSA PONUDE I POTRAŽNJE NA TRŽIŠTU RADA U REPUBLICI HRVATSKOJ	234

Ivan Madunić

UTJECAJ MJERE "OČUVANJE RADNIH MJESTA" NA ISPLATE RADNIČKIH TRAŽBINA U SLUČAJU STEČAJA ILI BLOKADE RAČUNA POSLODAVCA	254

Ante Rončević

Matija Kikelj

UTJECAJ POTPORE NOVOOSNOVANIM PODUZEĆIMA ZA INOVACIJE I RAZVOJ NOVIH PROIZVODA I USLUGA PUTEM FONDOVA EUROPSKE UNIJE U REPUBLICI HRVATSKOJ	283

POSTPANDEMIJSKA EKONOMSKA OČEKIVANJA

Ljubo Jurčić*

1. UVOD

Ekonomske krize su, bez obzira na to zbog čega su nastale, "sveti gral" ekonomske znanosti. One, na jednoj strani, otkrivaju stvarnu snagu gospodarstva, organiziranost i sposobnost države kao cjeline, a na drugoj strani, ispravnost i efikasnost ekonomskih politika koje su provedene u prethodnim razdobljima. Isto je i sa sadašnjom krizom koju je izazvala pandemija COVID-19. Zatvaranje, do upotrebe cjepiva, bila je glavna mjera za sprječavanje širenja epidemije (pandemije), što je dovelo do prekida domaćih, a još više međunarodnih proizvodnih lanaca. To je dovelo do usporenog kretanja roba, ali i ljudi. Transport i turizam bile su prve jasno vidljive djelatnosti koje je pogodila pandemija, da bi se taj udar s vremenom, više ili manje, proširio na sve ostale ekonomske aktivnosti, ali i na mnoge aspekte privatnog života. Osim pandemije, Zagreb i okolicu Zagreba pogodili su snažniji potresi.

Pandemija i potresi razotkrili su mnoge slabosti u strukturi, organizaciji i funkcioniranju hrvatske države, ali isto tako, razotkrili su slabosti ekonomske politike. Svijet i međunarodne ekonomske institucije poučene financijskom i ekonomskom krizom od prije desetak godina, sada su reagirali puno spremnije i puno efikasnije. Nije se robovalo ortodoksnim, ekonomsko političkim dogmama, nego se djelovalo po načelu: sve je dopušteno što može poslužiti za ublažavanje posljedica krize i za što brži izlazak iz nje. Hrvatska se također donekle držala tog pravila. Hrvatska politika nije napravila grešku kao u prošloj krizi, kad je svojim mjerama prije desetak godina, gurnula Hrvatsku u dublju i dužu krizu. Hrvatska je tek

* Prof. emer. dr. sc. Ljubo Jurčić, predsjednik Hrvatskog društva ekonomista.

2019. godine došla na razinu gospodarske aktivnosti iz 2008. godine, dok su europske tranzicijske zemlje u prosjeku te godine bile oko 30% iznad razine iz 2008. godine.

2. GOSPODARSTVO SVIJETA

Pristup cjepivima postao je glavna linija razdvajanja duž koje se globalni oporavak dijeli na dva bloka: one koji mogu očekivati normalizaciju gospodarske aktivnosti do kraja ove godine (to su gotovo sva razvijena gospodarstva) i one koji će se i dalje suočavati s ponovnim infekcijama i sve većom smrću od COVID-19, piše Međunarodni monetarni fond (WEO, July 2021). Oporavak, međutim, nije siguran čak ni u zemljama u kojima je infekcija trenutno vrlo niska sve dok virus cirkulira u bilo kojem obliku i bilo kojem dijelu zemaljske kugle.

Predviđa se da će globalno gospodarstvo porasti 6,0% u 2021. i 4,9% u 2022. godini (Tablica 1.). Izgledi za tržišta u nastajanju i gospodarstva u razvoju smanjeni su za 2021. godinu, posebno za Aziju u razvoju. Prognoza za razvijena gospodarstva uključuje smanjenje pandemije i promjene u politici za potporu gospodarstvu u kompenziranju šteta od pandemije. Bolje prognoze za 2022. godinu u velikoj mjeri proizlaze iz predviđanja boljeg razvoja situacije u razvijenim zemljama. Očekivanja su da će se u dovoljnom iznosu održati fiskalne potpore te da će se poboljšati zdravstvena situacija.

Pritisci na cijene uglavnom odražavaju neuobičajenu situaciju na tržištu stvorenu pandemijom, zbog smanjene proizvodnje, narušenih međunarodnih lanaca opskrbe, što je stvorilo prolaznu neusklađenost ponude i potražnje, osobito u reprodukcijskoj potrošnji. Normaliziranjem međunarodnih lanaca opskrbe očekuje se da će se inflacija u većini zemalja u 2022. godini vratiti na svoje razine prije pandemije, iako je neizvjesnost i dalje velika. Povišena inflacija također se očekuje u nekim tržištima i gospodarstvima u razvoju, djelomično je povezana s visokim cijenama hrane. Očekuje se da će središnje banke promatrati prolazne inflacijske pritiske i izbjegavati zaoštavanje monetarne politike (dizanje kamatnih stopa) sve dok ne budu jasniji temeljni izvori i dinamika cijena. Jasna komunikacija središnjih banaka o potezima monetarne politike bit će ključna za oblikovanje inflacijskih očekivanja i zaštitu od preranog zaoštavanja financijskih uvjeta.

Multilateralno djelovanje ima vitalnu ulogu u smanjenju razlika među zemljama, odnosno između razvijenih i manje razvijenih u jačanju globalnih

izgleda. Neposredni prioritet je ravnopravno raspoređivanje cjepiva u cijelom svijetu. Prijedlog MMF-a u iznosu od 50 milijardi dolara, koji su zajednički odobrile Svjetska zdravstvena organizacija, Svjetska trgovinska organizacija i Svjetska banka, daje jasne ciljeve i pragmatične akcije da se po prihvatljivoj cijeni suzbije pandemija. Financijski ograničena gospodarstva, manje razvijenih zemalja također trebaju neometan pristup međunarodnoj likvidnosti. Predložena opća raspodjela posebnih prava vučenja u iznosu od 650 milijardi dolara pri MMF-u trebala bi povećati snagu pričuve svih gospodarstava i smanjiti ograničenja likvidnosti. Složne, dobro usmjerene politike mogu napraviti razliku između budućnosti trajnog oporavka za sva gospodarstva, dok bi izostanak ovih politika gurnuo svijet u veću neizvjesnost.

Rizici globalnog oporavka su još uvijek dosta veliki i razvoj globalne gospodarske situacije idućih godina je dosta neizvjestan. Sporije uvođenje cjepiva od očekivanog potaknulo bi daljnju mutaciju virusa. Financijski uvjeti mogli bi se brzo pooštriti, osobito na području monetarne politike ako se inflacijska očekivanja povećavaju brže nego što se očekivalo. Dvostruki udar za zemlje u razvoju mogao bi doći zbog pogoršanja pandemijske situacije i zaoštavanja vanjskih financijskih uvjeta, što bi ozbiljno ugrozilo njihov oporavak i povuklo globalni rast ispod granica sadašnje prognoze. Podaci u Tablici 1. su iz travnja 2021. godine. Početkom rujna podaci o gospodarskom rastu u drugom kvartalu bili su puno optimističniji. Rast je bio iznad očekivanja u najvećem broju zemalja. Međutim, povećanje gospodarske aktivnosti na vidjelo je donijelo posljedice prekida međunarodnih lanaca opskrbe proteklih godinu dana pandemije. Pojavio se nedostatak sirovina i repromaterijala kao i prijevozničkih kapaciteta, zbog čega su porasle njihove cijene. U nekim dijelovima svijeta bile su jake suše ili poplave, što je smanjilo ponudu hrane. Sve zajedno dovelo je do povećanja cijena u mnogim dijelovima svijeta, najvećeg u proteklih tridesetak godina.

Pad BDP-a u 2020. godini, zbog pandemije, pokazao je otpornost pojedinih gospodarstava. Gospodarstva koja imaju lošu strukturu najviše su pogođena. To su u pravilu gospodarstva u čijoj strukturi BDP-a relativno velik udio ima turizam, koji je najosjetljiviji na vanjske utjecaje. Francuska, Italija, Španjolska i Hrvatska imaju najveći pad BDP-a zbog velikog udjela turizma u BDP-u. Taj udio u Hrvatskoj ne pokazuje toliko kvalitetu turizma, koliko pokazuje da je industrijska proizvodnja mala. Isto tako, ove zemlje

popuštanjem pandemijskih mjera i otvaranjem prema turizmu imat će u kratkom roku najveće stope rasta.

Tablica 1. Promjene BDP-a i proračunskog deficita

	BDP 2019.	DEFICIT 2019.	BDP 2020.	DEFICIT 2020.	BDP 2021.	DEFICIT 2021.	BDR 2022.	DEFICIT 2022.
SVIJET	2,8	-2,9	3,2	-11,7	6,0	-10,4	4,9	-4,6
SAD	2,2	-5,7	-3,5	-15,8	7,0	-15,0	4,9	-6,1
EURO	1,3	-0,6	-6,5	-7,6	4,6	-6,7	4,3	-3,3
NJEMAČKA	0,6	+1,5	-4,8	-4,2	3,6	-5,5	4,1	-0,4
FRANCUSKA	1,5	-3,0	-8,2	-9,9	5,8	-7,2	4,2	-4,4
ITALIJA	0,3	-1,6	-8,9	-9,5	4,9	-8,8	4,2	-5,5
ŠPANJOLSKA	2,0	-2,9	-10,8	-11,5	6,2	-9,0	5,8	-5,8
JAPAN	0,3	-3,1	-4,7	-12,6	2,8	-9,4	3,0	-3,8
UK	1,4	-2,3	-9,8	-13,4	7,0	-11,8	4,8	-6,2
KINA	5,8	-6,3	2,3	-11,4	8,1	-9,6	5,7	-8,7
INDIJA	4,0	-7,4	-8,0	-12,3	12,5	-10,0	6,9	-9,1
RUSIJA	2,0	+1,9	-3,0	-4,1	3,1	-0,8	3,8	-0,3
GRČKA	1,9	-0,6	-8,2	-9,9	3,8	-8,9	5,0	-2,6
HRVATSKA	2,9	+0,4	-8,2	-8,0	3,8	-3,9	5,0	-2,6
SLOVENIJA	3,2	0,5	-5,5	-8,5	3,7	-6,2	4,5	-4,2
SLOVAČKA	2,3	-1,4	-5,2	-7,3	4,7	-7,1	4,4	-4,9
POLJSKA	4,5	-0,7	-2,7	8,2	3,5	-4,7	4,5	-2,6
MAĐARSKA	4,6	-2,0	-5,0	-8,5	4,3	-6,5	5,9	-4,8

Izvor: IMF, WEO; April 2021, Fiscal Monitor, April 2021.

Pad BDP-a odrazio se i na povećanje deficita proračuna, što se dalje prenosi u povećanje javnog duga. Nakon depresije tridesetih godina prošlog stoljeća to je postao uobičajeni proces u kriznim situacijama: pad BDP-a, povećanje nezaposlenosti, povećanje proračunskog deficita i javnog duga. Prosjek deficita svih zemalja bio je u 2019. oko 2,9% BDP-a, da bi taj deficit u 2020. godini narastao na 11,7%. Dio deficita dolazi zbog pada proračunskih

prihoda, kao posljedica pada ekonomskih aktivnosti, a dio deficita dolazi iz dodatne državne potrošnje i potpora građanima i poduzetnicima radi usporavanja pada proizvodnje i očuvanja gospodarske aktivnosti, plus povećane naknade za nezaposlene i socijalno ugrožene.

3. EUROPSKA UNIJA

Poboljšanje zdravstvene situacije i kontinuirano ublažavanje mjera u suzbijanju virusa vraćaju gospodarstva EU-a u sve intenzivniju gospodarsku aktivnost. Kratkoročni izgledi za europsko gospodarstvo, početkom jeseni, izgledaju svjetliji nego što se očekivalo na proljeće. Smanjivanje BDP-a u prvom tromjesečju ove godine pokazalo se marginalnim i blažim od onog što je bila Eurostatova preliminarne proljetna prognoza. Nešto slično kao što je proljetna MMF-ova prognoza prikazana u Tablici 1. Sve manji broj novih infekcija i hospitalizacija, zahvaljujući učinkovitoj strategiji obuzdavanja i napretku u cijepljenju, doveo je države članice EU-a do ponovnog otvaranja svojih gospodarstava, a posebno u korist djelatnosti uslužnog sektora. Rezultati ankete među potrošačima i poduzećima ukazuju na to da je oporavak potrošnje već u tijeku i da će se ojačati u idućim mjesecima. Također, oživljavanje turističke aktivnosti pojačava optimizam. Očekuje se da će ti čimbenici nadmašiti privremene nedostatke inputa proizvodnje i sve veće troškove koji pogađaju dijelove proizvodnog sektora.

Predviđa se rast BDP-a od 4,8% u 2021. i 4,5% u 2022. u EU-u i europodručju. Očekivanja su da će se obujam proizvodnje vratiti na razinu prije krize (2019. – Q4) u posljednjem tromjesečju 2021. godine, što je za četvrtinu više od očekivanja u proljetnoj prognozi za europodručje. Brzina oporavka značajno će se razlikovati u državama članicama. Za neke se očekuje da će se gospodarska proizvodnja vratiti na razinu prije pandemije do trećeg tromjesečja 2021. godine, ali drugima će trebati više vremena.

Prognoza inflacije za ovu i sljedeću godinu također je revidirana naviše. Rast cijena energije i robe, uska grla u proizvodnji zbog nedostatka nekih ulaznih komponenti i sirovina te ograničenja kapaciteta u odnosu na rastuću potražnju u zemlji i inozemstvu ove će godine vršiti pritiske na povećanje potrošačkih cijena. Pretpostavlja se da će se pritisci 2022. godine postupno smanjivati kako se riješe ograničenja ponude, uklone zaostaci u narudžbama, a rast potražnje uspori. U skladu s tim, sada se predviđa (kolovoz 2021.) da će inflacija u EU-u u prosjeku iznositi 2,2% ove godine i

1,6% 2022. (+0,3 i +0,1 poena, u odnosu na proljetnu prognozu). U europodručju predviđa se da će inflacija u prosjeku iznositi 1,9% u 2021. (+0,2 pp.) i 1,4% u 2022. godini (+0,1 pp.).

Tablica 2. Eurostat: prognoza 2021. i 2022. godina

	GDP %			INFLATION %		
	2020	2021	2022	2020	2021	2022
Belgium	-6.3	5.4	3.7	0.4	2.1	1.7
Germany	-4.8	3.6	4.6	0.4	2.8	1.6
Estonia	-2.9	4.9	3.8	-0.6	2.2	2.4
Ireland	3.4	7.2	5.1	-0.5	1.5	1.2
Greece	-8.2	4.3	6.0	-1.3	-0.4	0.5
Spain	-10.8	6.2	6.3	-0.3	2.1	1.4
France	-7.9	6.0	4.2	0.5	1.6	1.2
Italy	-8.9	5.0	4.2	-0.1	1.4	1.2
Cyprus	-5.1	4.3	3.8	-1.1	1.4	1.3
Latvia	-3.6	3.8	6.0	0.1	2.0	2.1
Lithuania	-0.9	3.8	3.9	1.1	2.3	2.0
Luxembourg	-1.3	4.8	3.3	0.0	2.5	1.7
Malta	-7.8	5.6	5.8	0.8	1.1	1.6
Netherlands	-3.7	3.3	3.3	1.1	1.8	1.5
Austria	-6.3	3.8	4.5	1.4	2.1	1.9
Portugal	-7.6	3.9	5.1	-0.1	0.8	1.1
Slovenia	-5.5	5.7	5.0	-0.3	1.4	1.7
Slovakia	-4.8	4.9	5.3	2.0	2.1	2.2
Finland	-2.8	2.7	2.9	0.4	1.5	1.6
Euro area	-6.5	4.8	4.5	0.3	1.9	1.4
Bulgaria	-4.2	4.6	4.1	1.2	1.9	2.5
Czechia	-5.6	3.9	4.5	3.3	2.7	2.3
Denmark	-2.7	3.0	3.4	0.3	1.5	1.3
Croatia	-8.0	5.4	5.9	0.0	1.5	1.3
Hungary	-5.0	6.3	5.0	3.4	4.4	3.3
Poland	-2.7	4.8	5.2	3.7	4.2	3.1
Romania	-3.9	7.4	4.9	2.3	3.2	2.9
Sweden	-2.8	4.6	3.6	0.7	2.1	1.2
EU	-6.0	4.8	4.5	0.7	2.2	1.6

Izvor: Eurostat.

Neizvjesnost i rizici vezani za izgled rasta su visoki, ali su općenito uravnoteženi. Prijetnja koju predstavljaju širenje i pojava zabrinjavajućih varijanti virusa, naglašava važnost daljnjega brzog povećanja cijepljenja. Ekonomski rizici odnose se osobito na odgovor kućanstava i tvrtki na promjene ograničenja i utjecaj povlačenja potpora.

Inflacija bi mogla biti veća od predviđene ako su ograničenja ponude trajnija i ako se pritisci cijena snažnije prenose na potrošačke cijene

4. ZAKLJUČAK

Hrvatska je osim pandemije suočena sa stagniranjem proizvodnje proteklih desetak godina. Prema podacima Međunarodnog monetarnog fonda, europske zemlje u tranziciji (16 zemalja s tržištima u nastajanju i s gospodarstvima u razvoju) uključujući Bjelorusiju, Rusiju, Ukrajinu i Tursku, od 2003. do 2020. godine, u prosjeku su godišnje rasle oko 2,25%. Hrvatska je među zemljama s najmanjim prosječnim rastom od oko 0,74% godišnje. Poljska spada u zemlje s najvećim rastom, prosječno godišnje oko 3,1%, kod Mađarske je taj rast iznosio oko 2,4%, a kod Srbije 2,23%. Bruto domaći dohodak po stanovniku u 2020. godini (prema Eurostatu) iznosio je kod Poljaka 13.640 eura, kod Mađara 13.940 eura, kod Slovenaca 22.310 eura, kod Srba 6.730 eura, a kod Hrvata 12.170 eura. Bruto domaći proizvod Europske unije je oko 30 tisuća eura po stanovniku, a zemalja u eurozoni oko 33 tisuće eura. Matematički, iz ovog odnosa razvijenosti, mjereno BDP-om po stanovniku, Hrvatska bi sljedećih godina trebala imati tri puta veće stope rasta BDP-a po stanovniku da bi se približavala prosjeku Europske unije.

JEL klasifikacija: E23, E27

Pregledni rad

KOMPARATIVNA ANALIZA MJERA POMOĆI USLIJED PANDEMIJE COVID-19 U ODABRANIM ZEMLJAMA ČLANICAMA EU¹

Ana Lujčić*
Lucija Rogić Dumančić**

SAŽETAK

Potkraj 2019. godine pojavila se pandemija virusa COVID-19 koja je uzrokovala brojne promjene u gospodarstvu svih zemalja, a samim tim i promjene u životu i navikama ljudi. Koronavirus kao zdravstvena prijetnja postala je generator razvoja ekonomske krize u cijelom svijetu u brzom vremenu. Mjere obrane od virusa, u prvom redu zatvaranje (*lockdown*), spriječile su uobičajeno funkcioniranje ekonomija zbog čega je došlo do šokova u agregatnoj ponudi i potražnji, kao i očekivanjima. Gotovo sve europske zemlje uvele su određene mjere kako bi spriječile nekontrolirano širenje virusa. U ovom radu sagledava se utjecaj novonastale pandemije koronavirusa u Republici Hrvatskoj i u pojedinim državama članicama EU na odabrane makroekonomske pokazatelje. Cilj je istražiti mjere koje su pojedine države uvele kako bi pandemija koronavirusa ostavila što bezbolnije posljedice na gospodarstva određenih zemalja. Mjere koje su

* Ana Lujčić, mag. oec., Ekonomski fakultet Sveučilišta u Zagrebu (e-mail: ana.lujic2@gmail.com).

** Izv. prof. dr. sc. Lucija Rogić Dumančić, Ekonomski fakultet Sveučilišta u Zagrebu (e-mail: lrogic@efzg.hr).

¹ Rad je nastao u sklopu istraživanja za diplomski rad pod nazivom "Ekonomske posljedice virusa COVID-19 na gospodarstvo Republike Hrvatske" kandidatkinje Ane Lujčić pod mentorstvom izv. prof. dr. sc. Lucije Rogić Dumančić.

razmatrane odnose se na mala poduzeća, samozaposlene osobe i start-upove, zatim mjere koje se odnose na srednja i velika poduzeća, mjere za poduzetnike, mjere koje se tiču zaposlenih osoba, a razmatrane su i mjere koje se odnose na cjelokupno stanovništvo pojedinih zemalja članica, te mjere za poljoprivrednike. Zemlje analizirane u radu su: Savezna Republika Njemačka, Republika Češka, Republika Poljska, Republika Slovačka, Republika Slovenija i Republika Hrvatska. Treba imati na umu da pandemija virusa COVID-19 još uvijek nije gotova, te će se o konačnim posljedicama pandemije moći govoriti tek kada ona bude u potpunosti suzbijena. Daljnji razvoj situacije ovisi o epidemiološkoj situaciji, posebice o pojavi novih varijanata virusa te sposobnosti gospodarstava da se prilagode novim uvjetima većih nesigurnosti, kao i novih izazova poput zelene tranzicije i digitalizacije.

Ključne riječi: COVID-19, Hrvatska, EU, mjere pomoći, makroekonomske posljedice.

1. UVOD

Pandemija COVID-19 je najveći suvremeni šok koji su svjetske ekonomije iskusile. Proširila se cijelim svijetom te prouzročila brojne probleme gospodarstvima pojedinih zemalja. U Republici Hrvatskoj 11. ožujka 2020. godine proglašena je pandemija koronavirusa i od tada se sve mijenja, zatvarale su se državne granice, trgovine, kafići, restorani, uveo se rad od kuće, neke zemlje su čak uvele i policijski sat. Može se reći kako je pandemija znatno utjecala na navike ljudi, ali i na porast nezaposlenosti, kao i na druge ekonomske gubitke. Države su uvele brojne mjere u borbi protiv koronakrize, usmjerene na gospodarstvo i socijalna pitanja.

Ono što je izjava Marija Draghija "*whatever it takes*" postala 2012. godine, to je postala izjava "*next two weeks are the key*" u razdoblju pandemije koronavirusa. Proglašenje pandemije bilo je polazište za daljnje restriktivne mjere u većini gospodarstava EU, pa tako i Republici Hrvatskoj. Kao mjera za suzbijanje širenja virusa uvedeno je zaključavanje gospodarstva (*lockdown*). To se najviše odnosilo na one koji se bave uslužnom djelatnošću, što za posljedicu ima negativan šok na strani agregatne ponude². Oblik krize kao i trajanje recesije zasigurno ovisi o epidemiološkoj

² Više o makroekonomskim šokovima koji su pogodili gospodarstva tijekom pandemije pogledati u Čavrak (2020) i Rogić Dumančić et al. (2020).

situaciji pojedine zemlje, kao i o poduzetim mjerama makroekonomske politike. Za razliku od prethodne krize, gospodarstva su se našla u situaciji trenutnog potpunog prekida mnogih aktivnosti, što je dovelo do naglog pada proizvodnje, brzog porasta nezaposlenosti i pogoršanja životnog standarda (smanjenje realnog dohotka, nesigurnost radnih mjesta, ograničena mobilnost), drastičnog smanjenja prometa u vanjskoj trgovini unutar EU-a i s trećim zemljama te naglog pogoršanja pokazatelja javnih financija (Zahradnik et al., 2020).

Širenje pandemije COVID-19 predstavlja ozbiljan problem za globalnu ekonomiju i društvo. Postalo je jasno kako je EU postala epicentar širenja virusa, te da ne postoji jedinstven odgovor zemalja članica, stoga su države članice, kao i odgovarajuće institucije EU-a donijele niz hitnih, preventivnih, stabilizacijskih i kompenzacijskih mjera kako bi dali odgovor na novonastalu krizu. Te se mjere prema svojoj vrsti mogu podijeliti u nekoliko kategorija, npr. monetarne i stabilizacijske mjere, fiskalne mjere, mjere temeljene na jamstvima i zajmovima te regulatorne i postupovne mjere (Zahradnik et al., 2020). Spomenute mjere usmjerene su najviše na gospodarstvo i socijalna pitanja. U nekim zemljama, sve mjere koje su uvedene, uvedene su u obliku zakona ili prilagođavanja postojećeg zakonodavstva. U Poljskoj su mjere predviđene aktima vlade ili nadležnih ministarstava.

Europska središnja banka proširila je program kvantitativnog popuštanja u vidu otkupljenja dodatnih obveznica, omogućavanja jeftinih dugoročnih kredita prema bankama kako bi održale likvidnost, te ublažavanja uvjeta bankama za dobivanje zajmova. Europska unija pokrenula je inicijativu kao odgovor na koronavirus, uključujući 37 milijardi eura za sektor zdravstva, mala i srednja poduzeća i za potporu zaposlenicima (Zahradnik et al., 2020). Od dana 1. travnja 2020. godine primjenjuju se pravila za brže i fleksibilnije korištenje kohezijskih fondova EU-a, navedeno se posebno odnosi na izdatke koje su države članice ostvarile te i dalje ostvaruju od veljače 2020. godine.

Europska komisija (2020a) donijela je odluku o uvođenju privremenog okvira koji bi državama članicama omogućio iskoristiti potpunu fleksibilnost prema pravilima o državnim potporama, kao potporu gospodarstvu zbog izbijanja pandemije COVID-19. Predložena je aktivacija opće klauzule stabilnosti i rasta kako bi se efikasno i koordinirano reagiralo na pandemiju koronavirusa. Europska komisija koristi sve alate kako bi se

što više ublažili negativni učinci pandemije koronavirusa na gospodarstvo, a glavni ciljevi su: pružiti potporu fizičkim i pravnim osobama, opskrbiti zdravstveni sustav potrebnom medicinskom opremom, solidarnost na jedinstvenom tržištu, osigurati likvidnost financijskog sektora i omogućiti zemljama članicama EU da djeluju koordinirano, koristeći fleksibilnost Pakta o stabilnosti i rastu EU.

Europski gospodarski i socijalni odbor (EGSO) poziva na zeleni oporavak i na snažan socijalni i gospodarski oporavak te ističe da se tako ambiciozan program koji podrazumijeva korjenitu preobrazbu može ostvariti ako se temelji na šest načela, a to su: solidarnost, konkurentnost, održivost, zaštita radnih mjesta, zaštita dohotka i sudjelovanje (Zahradnik et al., 2020). Ako će mjere za oporavak biti jače, te se više prilagoditi stanju zemalja članica, a samim tim i stanovništvu tih zemalja, Europa će biti vjerodostojnija i sposobnija boriti se sa krizom koja je zahvatila cijeli svijet.

Zdravstveni sustav susreo se s brojnim problemima u razdoblju pandemije koronavirusa, povećani su izdatci za zdravstveni sustav, nedovoljan broj bolničkih postelja i medicinskog osoblja, medicinske i zaštitne opreme, nabava cjepiva kao i nagomilani dugovi za lijekove iz proteklih godina. Ako se pojavi novi val pandemije koronavirusa i novi sojevi virusa, te ako se ne cijepi dovoljan postotak stanovništva, mogao bi se ponoviti scenarij iz ožujka 2020. godine, a to će ponovno rezultirati negativnim posljedicama na gospodarstvo zemlje, a samim tim i na živote ljudi³. U svrhu sprječavanja širenja koronavirusa, države diljem Europe donijele su razne pakete mjera gospodarstvenicima. Stoga je glavni cilj ovog rada prikazati i usporediti odabrane mjere donesene u Hrvatskoj i odabranim članicama Europske unije.

Rad je podijeljen u četiri cjeline. Nakon uvodnih razmatranja, u drugom dijelu rada analiziraju se osnovni odabrani makroekonomski pokazatelji prije i nakon pojave pandemije COVID-19 u EU, kao i indeks strogosti epidemioloških mjera, dok se u trećem poglavlju analiziraju mjere za pomoć gospodarstvu unutar odabranih zemalja EU. Rad završava zaključnim razmišljanjima.

³ Potrebno je napomenuti kako se u određenim zemljama (primjerice Izrael i Island) virus širi unatoč visokoj procijepljenosti. Danska i Engleska ukidaju mjere zbog procijepljenosti, dok se Australija i Novi Zeland zatvaraju zbog manjeg broja slučajeva zaraženih.


2. MAKROEKONOMSKI POKAZATELJI PRIJE I NAKON POJAVE PANDEMIJE COVID-19 U EU

Kada je službeno objavljena pandemija virusa COVID-19, jasno je bilo kako će se to odraziti na ekonomska kretanja, pogotovo kroz moguću pojavu nove recesije. Prema Prašćević (2020), pandemija se smatra negativnim egzogenim šokom čije se djelovanje širi kroz ekonomski sustav, uzrokujući ekonomski pad i recesiju. Problematično je pričati o utjecaju nekog značajnog šoka koji pogađa ekonomiju, dok taj šok još djeluje, bez jasnih naznaka koliko dugo će biti prisutan. Procjene budućih ekonomskih kretanja ubrzano se mijenjaju, uslijed promjena dnevnog broja zaraženih i preminulih osoba u pojedinim zemljama, kao i promjena u mjerama koje donosi pojedina država, poput uvođenja karantene, socijalnog distanciranja, zatvaranja granica ili ublažavanja provedenih mjera.

Potkraj veljače 2020. godine, epidemiološka situacija znatno se pogoršala u cijelom svijetu te Europa počinje zatvarati granice između europskih zemalja, stavljajući po strani šengenski sporazum o slobodnom kretanju unutar EU. Borba s koronavirusom donosi sa sobom značajne ekonomske gubitke, kao što je porast nezaposlenosti, izgubljeni dohodak itd. Treba spomenuti da pandemija utječe i na svakodnevni život pojedinca zbog uvođenja mjere socijalnog distanciranja, tj. karantene. Pandemija će prouzrokovati kratko-ročne i dugoročne makroekonomske efekte. Prašćević (2020) navodi kako se makroekonomski troškovi i gubici koje je prouzrokovala pandemija koronavirusa odnose na smanjenje bruto domaćeg proizvoda (BDP), porast stope nezaposlenosti te pogoršanje drugih makroekonomskih veličina, što će ostaviti posljedice na stope ekonomskog rasta.

Iz Grafikona 1. vidljivo je da je u većini zemalja Europske unije stopa rasta BDP-a bila neprimjetno manja u četvrtom kvartalu 2019. godine, u usporedbi s prvim kvartalom iste godine. Uslijed *lockdowna* u drugom kvartalu 2020., stopa rasta naglo pada, te je pad stope rasta BDP-a na razini Europske unije iznosio -10,5% u drugom kvartalu 2020. u odnosu na prvi kvartal 2019. godine. Pritom je najdublji pad doživjela Španjolska (-17,3%), zatim Hrvatska, Italija, Malta i Portugal s oko -13%. Najmanji pad zabilježila je Irska (-0,10%), zatim Estonija (2,60%).

Grafikon 1. Stope promjene kvartalnog BDP-a




Izvor: Eurostat (2021).

Napomena: Podaci su sezonski prilagođeni. Stopa rasta prikazana je kao postotna promjena u odnosu na prethodno razdoblje.


Na idućem grafikonu prikazat će se kretanje osobne i državne potrošnje u prvom kvartalu 2019. te u drugom i četvrtom kvartalu 2020. godine.

Grafikon 2. Kretanje osobne i državne potrošnje te BDP-a u prvom kvartalu 2019. te drugom i četvrtom kvartalu 2020. godine


A – Q1 2019



B – Q2 2020



C – Q4 2020




Izvor: Eurostat (2021).

Napomena: Podaci su izraženi kao postotna promjena u odnosu na protekli kvartal i prilagođeni su sezonski. Stope promjene BDP-a očitavaju se na desnoj strani grafikona, a stope promjene u državnoj i osobnoj potrošnji očitavaju se na lijevoj strani grafikona.

Na Grafikonu 2. prikazano je kretanje osobne i državne potrošnje te BDP-a za prvi kvartal 2019. te drugi i četvrti kvartal 2020. godine. U A dijelu Grafikona 2. promatra se prvi kvartal 2019. godine i vidljivo je da su gotovo sve zemlje bilježile pozitivne stope rasta BDP-a (osim Latvije i Luksemburga), ali i pozitivne stope rasta u osobnoj te državnoj potrošnji. U Hrvatskoj su se stope rasta osobne i državne potrošnje u odnosu na prošli kvartal kretale oko 1%, a najuvjerljivije stope rasta imala je Irska. Na dijelu grafikona koji je označen sa B promatraju se ta ista kretanja, ali u drugom kvartalu 2020. godine. Uzme li se u obzir da je u većinu zemalja koronavirus stigao u prvom kvartalu, jasno je da će se to u drugom kvartalu odraziti na brojeve budući da se uspoređuju s proteklom kvartalom. I na ovom prikazu opet se potvrđuje negativna stopa promjene BDP-a za sve zemlje bez iznimke. Primjetan je i pad osobne potrošnje, i to snažniji od pada BDP-a, dok je državna potrošnja u samo nekim zemljama pala na razine manje u odnosu na prošli kvartal. U Hrvatskoj je u drugom kvartalu 2020. godine osobna potrošnja pala za 12,8 %, a državna potrošnja za 3%. Na dijelu grafikona koji se odnosi na četvrti kvartal 2020. godine i označen je slovom C može se vidjeti lagan oporavak stopa rasta BDP-a kod nekoliko zemalja među kojima je i Hrvatska, kao i postupni oporavak državne i

osobne potrošnje, iako je osobna potrošnja još uvijek u većini zemalja s negativnim predznakom.

Grafikon 3. Veza promjene zaposlenosti i stope promjene BDP-a u drugom kvartalu 2020. godine



Izvor: Eurostat (2021).

Na Grafikonu 3. dovedeni su u vezu stopa promjene zaposlenosti sa stopom promjene BDP-a u drugom kvartalu 2020. godine. Bilo je za očekivati da će zaposlenost više pasti u zemljama koje su se suočile s dubljim padom BDP-a. Ipak, to se nije dogodilo. Pad stope zaposlenosti pratio je promjenu pada BDP-a, ali te dvije veličine nisu tako snažno povezane. Za usporedbu, zemlje koje su bile najviše pogođene pandemijom ostvarile su znatno slabije negativne efekte na zaposlenost od situacije u krizi 2009. godine. Oštar pad zaposlenosti zabilježen je u mediteranskim zemljama s obzirom na njihovu izloženost sektoru turizma (prijevoz, smještaj i ugostiteljstvo). Uz navedena strukturna obilježja tržišta rada Anderton i dr. (2020) navode i institucionalni okvir tržišta rada kao nedostajuću kariku u odnosu između kretanja agregatne proizvodnje i tržišta rada. Države članice koje imaju strože radno zakonodavstvo više koriste opcije skraćenoga radnog vremena s državnim sufinanciranjem troška rada u odnosu na otpuštanje radnika u situaciji (privremenog) smanjenja potražnje. Viša zaštita zaposlenosti nerijetko rezultira segmentiranim tržištem rada u kojem privremeno


zaposleni služe kao "buffer" u slučaju volatilnosti potražnje, što se dogodilo tijekom velikog zatvaranja 2020.

Prema Surico i Galeotti (2020) radna mjesta su manje gubili oni kojima je omogućen rad od kuće. Takvu priliku dobili su visokokvalificirani zaposlenici (u sektorima obrazovanja, korporativnih poslova i financija), tj. oni koji zarađuju u prosjeku više. Prethodno citirano istraživanje, prema našem mišljenju, zanemaruje ono što smatramo znatno važnijim za slabljenje veze između stope promjene zaposlenosti i stope rasta. Slabljenje veze valja povezati sa izdašnim vladinim transferima. Samo na hrvatskom primjeru može se ustanoviti da je otprilike 5% ukupnih rashoda državnog proračuna odlazilo na potpore za očuvanje radnih mjesta djelatnostima pogođenima pandemijom COVID-19, a sa sličnim izazovom suočile su se i druge zemlje EU, pa i svijeta. Sam udio na hrvatskim podacima možda i ne djeluje velik, ali ga možemo usporediti s drugim stavkama. Tako je, primjerice, neposredno pred krizu u razdoblju od 2015. do 2019. godine između 55 i 60% svih državnih subvencija odlazilo na poljoprivredu. Godine 2020. iznos subvencija je bio udvostručen, i to zbog mjera pomoći izloženima od COVID-19. Na godišnjoj razini 2020. godine je otprilike 50% subvencija otišlo na posljedice COVID-19, a od toga cjelokupnog iznosa 50% se odnosi na vrijeme tvrdog zatvaranja od ožujka do svibnja. Prema kraju 2020. i tijekom 2021. godine ukupan je iznos pomoći smanjen u apsolutnom iznosu, ali i dalje relativni odnos ostaje nepromijenjen (otprilike 50% subvencija i 5% ukupnih rashoda). Sam šok u subvencijama značajno je narušio fiskalnu poziciju države, ali je ona još i više bila pogoršana kroz smanjenje prihoda posebice PDV-a i trošarina tijekom strogog zatvaranja. Druga stavka koja odražava veličinu ovih subvencija su izdvajanja za kamate. Tijekom 2020. godine izdvajanja za potpore za očuvanje radnih mjesta djelatnostima pogođenima pandemijom (subvencije) tek su oko 300 milijuna manja od izdvajanja za kamate. Kad se tome dodaju i naknade kućanstvima koje se odnose na posljedice pandemije, izdatci za kamate su i premašeni, a ukupna veličina pomoći iznosi oko 5,1% državnog proračuna za 2020. godinu. Valja napomenuti da je ovdje načinjena usporedba pomoći za posljedice pandemije sa stavkom koja je usred prošle krize (2009. – 2014.) bila jedna od najbrže rastućih stavki državnog proračuna s kumulativnim rastom od 2,3 puta između 2008. i 2015. godine premda je zbog različitih uvjeta na svjetskim financijskim tržištima i dinamika kamata danas drukčija. Slična situacija vrijedi i za druge zemlje. Zašto valja istaknuti značaj ovih mjera? Iz ekonomske teorije je znano da će

poduzetnici s opadanjem prometa biti primorani otpuštati zaposlene kako bi smanjili troškovnu stavku. S povećanjem pomoći Vlade njima je zadržavanje broja zaposlenih primamljivije jer su troškovi u značajnoj mjeri kompenzirani, a s druge strane se očekuje da će šok biti kratkotrajan te da će u budućnosti rasti potražnja za radnom snagom koja se već sada pokazuje oskudnom. Valja istaknuti da je, unatoč izdašnosti, efekt ovih mjera na tržištu rada ipak ograničen jer je ukupna zaposlenost pala, a to se onda odražava i u većoj stopi nezaposlenosti. Drugi razlog za ograničenost ovih mjera je poznati dualitet na tržištu rada jer su njima pomognuti upravo trenutno zaposleni. Dakle, oni koji prvi put traže posao su u nepovoljnijoj poziciji, što pridonosi većoj stopi nezaposlenosti. Treba također istaknuti i glasove poduzetnika koji još uvijek prigovaraju na aktivnosti Vlade. Bez obzira na to što nisu idealne, u prilog ovim mjerama govori ono što se često povlači u kriznim situacijama – načelo fiskalnog multiplikatora. Brojna istraživanja iz vremena europske dužničke krize bila su potvrdila da u kriznim uvjetima fiskalni multiplikator ima tendenciju rasta (Hernandez de Cios i Moral Benito, 2016; Šimović i Deskar-Škrbić, 2013; Grdović Gnip, 2011). Upravo to načelo sugerira da bi bez mjera pomoći i ovako rekordan pad gospodarske aktivnosti u Hrvatskoj bio još i gori. No priču valja proširiti i izvan hrvatskih okvira jer je šok paralelno pogodio velik dio svijeta, a to onda i povećava multiplikativne efekte šoka. Tada bi i veza između negativne stope rasta BDP-a i negativne stope promjene zaposlenosti bila "očuvana". Sasvim je sigurno da bi bez izostanka zajedničke pomoći i europski integracijski procesi također bili narušeni.

Na Grafikonu 4. prikazan je indeks strogosti epidemioloških mjera. Riječ je o složenoj mjeri koja se temelji na devet indikatora, poput zatvaranja škola, zatvaranja radnih mjesta, zabrane putovanja. Indeks se kreće od 0 do 100 (100 = najstrože).

Grafikon 4. Indeks strogosti epidemioloških mjera za odabrane zemlje EU



Izvor: Our World in Data (2020).

Iz Grafikona 4. vidljivo je kako su odabrane zemlje uglavnom imale sličan trend kretanja indeksa strogosti epidemioloških mjera. Od promatranih zemalja, pred kraj promatranog razdoblja, Republika Hrvatska je imala najmanje stroge mjere, dok je Njemačka imala najstrože. U idućem dijelu rada dane su strategije suočavanja s virusom među odabranim zemljama članicama EU i u Republici Hrvatskoj.

3. MJERE ZA POMOĆ GOSPODARSTVU UNUTAR EU

U ovom dijelu rada prikazane su mjere za odabrane zemlje članice EU (Savezna Republika Njemačka, Češka, Poljska, Slovačka, Slovenija i Republika Hrvatska). Pritom su se prikazale mjere koje se odnose na samozaposlene osobe, mala poduzeća i start-upove, mjere koje se odnose na srednja i velika poduzeća, mjere koje se odnose na poduzetnike, mjere koje se odnose na zaposlene osobe, mjere koje se odnose na cjelokupno stanovništvo, te finalno, mjere koje se odnose na poljoprivrednike.

Mjere koje se odnose na samozaposlene osobe, mala poduzeća i start-upove

Mjere koje provodi Savezna Republika Njemačka, a odnose se na mala poduzeća, start-upove i samozaposlene osobe su: izravna bespovratna subvencija u iznosu od 50 milijardi eura za poduzeća. Za poduzeća sa do 5 zaposlenih, subvencija iznosi 9.000 eura, a za poduzeća koja imaju do 10 zaposlenih, navedena subvencija iznosi 15.000 eura. Nadalje, malim poduzećima, start-upovima i samozaposlenim osobama omogućuju se zajmovi s niskim kamatama putem banke za obnovu (KfW⁴), gdje Vlada preuzima do 100% rizika neizvršenja obveza. Omogućen je iznos od 7,5 milijardi eura za olakšan pristup osnovnoj sigurnosti samozaposlenih osoba, te iznos od 2 milijarde eura za javne investitore rizičnog kapitala za financiranje start-upova (AHK⁵, 2020). Suprotno tome, Republika Češka uvela je mjere koje se tiču samozaposlenih osoba, a neke od njih su: oslobođenje samozaposlenih osoba od plaćanja predujma minimalne premije zdravstvenog osiguranja u razdoblju od ožujka 2020. do kolovoza 2020. godine, kao i oslobođenje samozaposlenih osoba od plaćanja minimalnog obveznog iznosa doprinosa mirovinskog osiguranja u razdoblju od ožujka 2020. do kolovoza 2020. godine. U Republici Češkoj, samozaposlena osoba čije je dijete između 6 i 13 godina ima pravo na naknadu za brigu o djetetu, pod uvjetom da tu naknadu ne koristi drugi član obitelji. Naknada iznosi 15,50 eura dnevno, a najviše 478 eura mjesečno. Također, samozaposlene osobe imaju pravo tražiti bonus ako ne mogu obavljati posao, što zbog rizika od zaraze koronavirusom, što zbog nedostatka sirovina ili proizvoda za kvalitetno obavljanje djelatnosti. Definiran je kompenzacijski bonus koji iznosi 918 eura. Slično je uvela i

⁴ KfW – German Development Bank (Kreditanstalt für Wiederaufbau).

⁵ AHK – Auslandshandelskammer.

Republika Poljska. Naime, osnovan je poljski razvojni fond kojim se pruža pomoć mikro i srednjim poduzećima u vezi s gubitcima prouzrokovanim pandemijom koronavirusa (Istraživački centar, 2020).

U ožujku 2020. godine Vlada Republike Hrvatske usvojila je privremenu mjeru suspenzije potpora za samozapošljavanje i zapošljavanje s ciljem osiguranja dodatnih sredstava za očuvanje radnih mjesta u sektorima pogođenima koronavirusom. Upravno vijeće Hrvatskog zavoda za zapošljavanje 29. lipnja 2020. godine donijelo je odluku o stavljanju izvan snage Odluke o privremenoj obustavi dijela programa mjera aktivne politike zapošljavanja iz nadležnosti Hrvatskog zavoda za zapošljavanje u 2020. godini koja je donesena na sjednici Upravnog vijeća Hrvatskog zavoda za zapošljavanje dana 20. ožujka 2020. Najvažnije promjene odnose se na potporu za samozapošljavanje, te potporu za proširenje poslovanja, potporu za očuvanje radnih mjesta u sektorima pogođenim virusom COVID-19 za srpanj 2020., kao i potporu o skraćivanju radnog vremena (Ministarstvo rada, mirovinskoga sustava, obitelji i socijalne politike, 2020). Izmjene kod potpora za samozapošljavanje odnose se na trajanje mjere. Prema novim uvjetima ugovorno razdoblje traje 24 mjeseca umjesto dosadašnjih 12 mjeseci. Potpora za samozapošljavanje dijeli se na dvije skupine korisnika u iznosima od 75.000,00 HRK do 100.000,00 HRK, ovisno o djelatnosti kojom se samozaposlena osoba bavi. Za obje skupine moguće je dodatno odobrenje u iznosu od 10.000,00 HRK za jedan poslovni subjekt, ako se potpora za samozapošljavanje kombinira s osposobljavanjem na radnom mjestu (Hrvatski zavod za zapošljavanje, 2020).

Ako su samozaposlenoj osobi u Republici Slovačkoj prihodi smanjeni više od 20%, Vlada će nadoknaditi zaradu u iznosu od 180 eura, za svaki mjesec sa smanjenim prihodom. Nadalje, ako su prihodi samozaposlene osobe smanjeni više od 40%, Vlada nadoknađuje zaradu u iznosu od 300 eura, za svaki mjesec u kojem su prihodi smanjeni. Ostvari li samozaposlena osoba prihode koji su smanjeni više od 60%, Vlada će nadoknaditi zaradu u iznosu od 420 eura, za svaki mjesec sa smanjenim prihodima. Ako su prihodi samozaposlene osobe smanjeni za više od 80%, Vlada nadoknađuje zaradu u iznosu od 540 eura, za svaki mjesec u kojem su prihodi smanjeni. Republika Slovačka osigurava doprinose samozaposlenim osobama koji su prisiljeni zaustaviti svoj rad kako bi se spriječilo širenje pandemije koronavirusa, ili onima čiji su prihodi smanjeni. Iznos doprinosa ovisi o smanjenju prihoda 2020. godine u usporedbi sa istim razdobljem u 2019. godini. Samozaposlene osobe Republike Slovenije imaju mogućnost odgode

za uplatu doprinosa za socijalno osiguranje za mjesec travanj, svibanj i lipanj 2020. godine. Navedeni doprinosi moraju se podmiriti najkasnije do 31. ožujka 2020. godine. Doprinosi za mirovinsko i zdravstveno osiguranje za to vrijeme uplaćuje država, a korisnik zadržava sva postojeća socijalna prava. Također, samozaposlene osobe u Sloveniji koje nisu u mogućnosti obavljati svoje poslovne aktivnosti ili su one smanjene najmanje 25% u usporedbi s proteklom mjesecom, ili najmanje 50% u mjesecu travnju i svibnju u odnosu na mjesec veljaču, imaju pravo na osnovni mjesečni prihod u iznosu od 350 eura za mjesec ožujak i 700 eura za mjesec travanj i svibanj 2020. godine (Istraživački centar, 2020).

Mjere koje se odnose na srednja i velika poduzeća

Mjere koje se odnose na srednja i velika poduzeća, a provodi ih Savezna Republika Njemačka su: odobreni krediti s niskim kamatama putem banke za obnovu (KfW), zatim, brzi krediti gdje vlada snosi rizik neispunjena obveza (maksimalno 500 000 eura za poduzeća koja imaju od 11 do 49 zaposlenih osoba, te najviše 800 000 eura za poduzeća koja imaju 50 ili više zaposlenih osoba). Sljedeća mjera koju provodi Vlada Savezne Republike Njemačke, a odnose se na srednja i velika poduzeća je iznos od 400 milijardi eura za jamstva likvidnosti, te osnovani fond za stabilizaciju gospodarstva sa 100 milijardi eura za kapitalne mjere i ulaganja u kapital (AHK, 2020). Slične mjere provodi i Republika Češka. Naime, malim i srednjim poduzećima omogućeni su krediti s jednogodišnjom odgodom plaćanja kamata koje omogućuje Ministarstvo za trgovinu i industriju u suradnji sa Češko-moravskom bankom. Također, malim i srednjim poduzećima omogućeni su komercijalni krediti u suradnji sa Češko-moravskom bankom, te garancija otplate kredita za poduzeća koja se bave izvozom, kao i proizvodnim i komercijalnim aktivnostima kako bi se osigurala likvidnost poduzeća (Istraživački centar, 2020).

U Republici Slovačkoj, ako su prihodi poduzeća ili samozaposlenih osoba smanjeni za više od 40%, odgađa im se plaćanje doprinosa za mirovinsko i zdravstveno osiguranje. Poslodavci i samozaposlene osobe u Republici Slovačkoj ne moraju uplaćivati doprinose za zdravstveno i mirovinsko osiguranje za mjesec travanj 2020. godine ako su imali prekid u poslovanju najmanje 15 dana. Poduzeća u Republici Sloveniji, koja u vrijeme pandemije obavljaju svoj posao te isplaćuju plaću zaposlenicima, oslobođena su od plaćanja mirovinskog i invalidskog osiguranja, te su poslodavci obvezni svim zaposlenim osobama za vrijeme pandemije, čija

plaća ne prelazi iznos trostruke minimalne plaće, uplaćivati mjesečni krizni dodatak koji iznosi 200 eura. Nadalje, Republika Slovenija osigurala je isplatu naknada za rad zaposlenicima koji obavljaju opasne poslove, te onima koji imaju povećan obujam posla tijekom pandemije (Istraživački centar, 2020).

Za kulturni sektor Republike Poljske pruža se financijska pomoć fizičkim i pravnim osobama kako bi promijenili oblik održavanja pojedinih umjetničkih aktivnosti. Produžuje se rok za predaju financijskih izvještaja. Republika Hrvatska i Republika Slovenija su također produžile rok za predaju financijskih izvještaja. Prema Zakonu o računovodstvu Republike Hrvatske, rok za predaju financijskih izvještaja je do 30. travnja tekuće godine za prošlu godinu, no taj rok se produžio na 30. lipnja 2020. godine. Ukida se obveza plaćanja naknade Fini za objavu godišnjih financijskih izvještaja (Vlada RH, 2020; Istraživački centar, 2020).

U Republici Poljskoj provodi se mjera oslobođenja plaćanja poreza na uvoz medicinske opreme, medicinskih proizvoda i aktivnih supstanci, dezinfekcijskih sredstava, dijagnostičkih medicinskih uređaja, laboratorijskih staklenih predmeta i aparata, zaštitne opreme i specijaliziranih dijagnostičkih testova za analizu patogenih agensa u ljudskom tijelu, vodi, zraku i zemlji. Kada je riječ o pojedinim sektorima, treba istaknuti kako Savezna Republika Njemačka provodi mjere kako bi olakšala zdravstvenom sektoru svoje zemlje. Savezna Republika Njemačka osigurala je iznos od 2,8 milijardi eura kao kompenzaciju za odgođena liječenja, te iznos od 2 milijarde eura za krevete za intenzivniju njegu u bolnicama. Također, osigurana je središnja nabava zaštitne opreme za bolnice i medicinske prakse, te je osigurana nabava ventilacijske opreme (Istraživački centar, 2020).

Republika Češka pruža pomoć turističkim agencijama tako što isplaćuju vaučer osobama koje su ranije rezervirale i uplatile svoje putovanje, ali zbog pandemije koronakrize ne mogu isto ostvariti. Ako kupac ne iskoristi vaučer u roku od godinu dana, tada turistička agencija vrši povrat uplaćenih novčanih sredstava. Trudnice, osobe s invaliditetom, osobe koje su na burzi rada te starije osobe od 65 godina ovaj vaučer mogu odbiti. Slično je uvela i Republika Hrvatska, Vlada Republike Hrvatske donijela je odluku o odgodi ili potpunom oslobođenju plaćanja turističke članarine gospodarskim subjektima i privatnim iznajmljivačima. Također, donesena je odluka o odgodi ili oslobođenju plaćanja turističke pristojbe za privatne

iznajmljivače. Osigurana je potpora za programe financiranja obrtnih sredstava te poboljšanja likvidnosti ugroženih gospodarstvenika u turizmu, to se posebno odnosi na male hotele. Promjenjivi dio koncesijske naknade neće se naplaćivati za turističko zemljište u kampovima u suvlasništvu države. Na temelju izmjena i dopuna Zakona o pružanju usluga u turizmu, uveden je moratorij na raskid ugovora za agencijske aranžmane u trajanju od 180 dana od završetka posebnih okolnosti, čime se osigurava povrat novčanih sredstava za neiskorišteni aranžman (Vlada RH, 2020). Nadalje, u Republici Hrvatskoj osnovan je krizni fond koji samostalnim umjetnicima, samozaposlenim osobama, drugim fizičkim i pravnim osobama koje su ostale bez svih prihoda kao rezultat zabrane ili ograničenja okupljanja i zatvaranja kina, koncertnih dvorana, kazališta ili muzeja osigurava potporu likvidnosti, ukupni iznos od 70 milijuna kuna. Donesena je odluka kako se obustavlja plaćanje spomeničke rente. Fizičkim i pravnim osobama iz sektora kulture koje svoje odobrene projekte ne mogu izvršiti zbog pandemije koronavirusa, isplaćuju se sredstva iz novoosnovanoga kriznog fonda.

Mjere koje se odnose na poduzetnike

Njemačka je osnovala fond za stabilizaciju gospodarstva uslijed pandemije koronavirusa (*Wirtschaftsstabilisierungsfonds*) s iznosom do 500 000 milijardi eura za pružanje likvidnosti i kapitalnu podršku poduzećima koja su pogođena pandemijom koronavirusa. Potpora je u obliku jamstava za koja se očekuje da će mobilizirati 400 milijardi eura od ukupnog iznosa, zatim zajmova i dokapitalizacije, ukupno do 100 milijardi eura. U pogledu potpora u obliku jamstava, osnovni iznos kredita po poduzeću ograničen je na ono što je potrebno za pokrivanje njegovih potreba za likvidnošću u bliskoj budućnosti, jamstva su osigurana samo do kraja 2020. godine, ograničena su na najviše šest godina te pokrivaju do 90% rizika. Komisija je zaključila da će njemačka mjera pridonijeti upravljanju ekonomskim učinkom izbijanja koronavirusa u Njemačkoj te je odobrila mjere prema pravilima EU o državnim potporama. Osim 500 milijardi eura koje je Komisija odobrila, fond može prikupiti do 100 milijardi eura za refinanciranje mjera državnih potpora o kojima je Komisija već obavijestila i odobrila, čime se ukupni proračun *Wirtschaftsstabilisierungsfonds* povećava na 600 milijardi eura (Europska komisija, 2020b).

Republika Češka pruža pomoć cjelokupnom stanovništvu, kao i poduzetnicima kroz oslobođenje plaćanja novčanih kazni zbog nepoštivanja

roka za podnošenje poreznih prijava i izvještaja, a kazne se ukidaju automatski. Nadalje, odgađa se rok za podnošenje prijava poreza na dobit i poreza na dohodak. Osnovan je institut retroaktivnog efekta poreznog gubitka koji se odnosi na porez na osobni dohodak i porez na dobit 2020. godine. Ukidaju se novčane kazne za kašnjenje porezne prijave za porez na nepokretnost, te se odgađaju svi sudski postupci. Kao bitnu mjeru koju provodi Republika Češka treba spomenuti poništavanje zahtjeva za pokretanje stečaja, reorganizacijom ili otplatom duga koji su bili predani do kraja mjeseca kolovoza 2020. godine. Slično je učinila i Republika Hrvatska, poduzete su mjere kako bi se olakšao položaj pojedinaca s ovrhom na plaći ili mirovini ili nekom drugom obliku primanja. Isto tako, poduzete su mjere kako bi se olakšao položaj gospodarskih objekata kojima prijeti stečaj te kako bi se olakšao položaj korisnicima bespovratnih sredstava za provedbu projekta (Vlada RH, 2020; Istraživački centar, 2020).

U Republici Češkoj su zdravstveni sektor, vojska socijalna zaštita i integrirani sustav spašavanja oslobođeni plaćanja PDV-a za isporuku određene robe i usluga. Također se odgađa plaćanje putnog poreza koji obuhvaća sva vozila koja su registrirana u Republici Češkoj, a koriste se u poslovne aktivnosti. Treba spomenuti kako zakon predviđa izuzeće od obveze korištenja elektronske registracije prihoda, osim obveze obrade podataka o autentičnosti i potvrde o evidenciji prodaje kako bi se spriječila njihova zloupotreba. Izuzeće traje tijekom izvanrednog stanja, kao i tri mjeseca nakon završetka izvanrednog stanja. Za poduzetnike u građevinarskom sektoru Republike Češke, također je uveden paket mjera, a odnosi se na prometnu infrastrukturu (održavanje, popravci postojeće prometne infrastrukture te nova ulaganja), te su produženi rokovi za završetak projekata koji su ranije ugovoreni. U Republici Slovačkoj osigurani su doprinosi za poslodavce u obliku kompenzacije do 80% prosječne plaće zaposlenih osoba, a najviše do 880 eura za sve zaposlene koji ne mogu obavljati svoj posao zbog izvanredne situacije. Druga opcija je fiksni doprinos za dio troškova zarada za svaku zaposlenu osobu na osnovi smanjenja prihoda. Mjere koje provodi Republika Poljska, a odnose se na poduzetnike su: oslobođenje plaćanja doprinosa za socijalno i zdravstveno osiguranje za poduzeća koja imaju do 10 zaposlenih. Navedeno vrijedi i za samozaposlene osobe. Izmijenjeni su uvjeti i rokovi otplate kredita za mikro, mala i srednja poduzeća. Poduzetnicima čije je poslovanje prekinuto zbog pandemije, isplaćuje se 50% minimalne plaće, kao i plaćanje doprinosa za socijalno osiguranje. Ukoliko postoji nemogućnost odvijanja

raznih kongresa, izložbi, kulturnih, sportskih i drugih sadržaja, produžuje se rok za povrat novaca klijentima u roku od 180 dana od dana raskida ugovora (Istraživački centar, 2020.).

Republika Hrvatska omogućava moratorij poduzetnicima čiji je kredit odobren od HBOR-a ili preko poslovne banke, moratorij je u trajanju od tri mjeseca i odnosi se na obveze dospjele nakon 29. veljače 2020. godine, uz mogućnost produljenja. Također, omogućeno im je reprogramiranje dosadašnjih kreditnih obveza uz uvođenje počeka u otplati glavnice kredita. Hrvatska banka za obnovu i razvitak (HBOR) zajedno s poslovnim bankama daje pravo poduzetnicima na nove kredite za likvidnost uz povoljniju kamatnu stopu. Europska komisija odobrila je dva nova programa kako bi Hrvatska banka za obnovu i razvitak pružila potporu gospodarstvu. Prvi odobreni program odnosi se na financiranje likvidnosti izvoznika kroz police osiguranja. Drugi odobreni program odnosi se na instrumente povoljnih kredita Hrvatske banke za obnovu i razvitak uz subvencije kamate koju je osigurala Republika Hrvatska. Navedeno se provodi u tri modela, a to su okvirni krediti bankama, krediti u suradnji s bankama po modelu podjele rizika i izravni krediti gospodarstvenicima. Kreditna sposobnost za navedenu mjeru iznosi 7,6 milijardi kuna. Nadalje, poduzetnicima u RH čiji je pad prihoda veći od 20%, ili poduzetnicima koji su ustanovili kako će imati takav pad prihoda, omogućena je beskamatna odgoda i obročna otplata izravnih poreza i doprinosa. Ova mjera je razrađena kada se usvojio drugi paket mjera u travnju. Poduzetnici čiji je godišnji prihod manji od 7,5 milijuna kuna, a imaju pad prihoda veći od 50%, oslobođeni su plaćanja javnih davanja koja dospijevaju u travnju, svibnju i lipnju 2020. godine. Ona poduzeća čiji je prihod veći od 7,5 milijuna kuna, ali imaju pad prihoda veći od 50%, djelomično su oslobođena plaćanja javnih davanja koja dospijevaju u travnju, svibnju i lipnju 2020. godine ovisno o tome koliko iznosi pad prihoda. Kako bi se osigurala dodatna likvidnost gospodarskih subjekata, postoji mogućnost plaćanja PDV-a po plaćenim i naplaćenim računima (Vlada RH, 2020).

Mjere koje se odnose na zaposlene osobe

Mjere koje provodi Savezna Republika Njemačka, a tiču se zaposlenih osoba očituju se kroz produženi dodatak za kratkoročno zaposlenje, zatim, pojednostavnjen je pristup osnovnoj sigurnosti bez financijske revizije i dječjem doplatku. Zaposlenim osobama isplaćuju se bonusi do 1500 eura, bonusi su oslobođeni poreza. Roditelji primaju djelomičnu naknadu za

gubitak zarade zbog brige o djeci, mjesečne roditeljske potpore mogu se odgoditi (AHK, 2020). Slično provodi i Republika Češka, u slučaju izolacije ili brige o djeci, zaposlenoj osobi se isplaćuje naknada zarade u iznosu od 100% prosječne plaće. Jednako tako, Republika Slovenija zaposlenim osobama koje su primorane ostati kod kuće kako bi vodile brigu o djeci tijekom pandemije ili onima koji ne mogu doći na posao zbog ukidanja javnog prijevoza ili zatvaranja državnih granica, isplaćuje 80% plaće, umjesto 50% kako je bilo prvobitno dogovoreno. Zaposlene osobe koje završe u samoizolaciji imaju pravo na naknadu tijekom bolovanja u iznosu od 90% plaće tijekom prvih 90 dana, a nakon toga 100% plaće, što uplaćuje Zavod za zdravstveno osiguranje Republike Slovenije. Zaposlenim osobama koje obavljaju posao od kuće, isplaćuje se mjesečna naknada u iznosu od 80% prosječne plaće u prethodna tri mjeseca. Zaposlene osobe koje završe u izolaciji, a nisu u mogućnosti obavljati posao od kuće, imaju pravo na mjesečnu naknadu u iznosu od 80% plaće. Republika Slovenija uvela je dodatak za zaposlene osobe koje su posebno izložene riziku zaraze, dodatak iznosi 100% osnovne zarade za sat vremena rada, kao i obvezu odgode plaćanja kreditnih obveza na 12 mjeseci, svim osobama kojima je rad zabranjen uredbom Vlade (Istraživački centar, 2020).

U slučaju da zaposlena osoba u Republici Češkoj završi u izolaciji, isplaćuje joj se naknada zarade u iznosu od 60% prosječne plaće. Slično je učinila Republika Slovačka gdje agencija za socijalno osiguranje zaposlenim osobama vrši isplatu plaće u uvjetima izolacije ili karantene. Osigurane su naknade za zaposlene osobe u Republici Slovačkoj, iznos je utvrđen kolektivnim ugovorom, uz poštivanje granice od 80% prosječne zarade zaposlenih osoba kao i maksimalne vrijednosti u iznosu od 1100 eura. Republika Slovenija refundira plaće zaposlenim osobama koje privremeno ne rade kako bi se spriječilo širenje pandemije, kao i zaposlenicima koji su u izolaciji te ne mogu obavljati svoj posao, također je uvedena odgoda plaćanja doprinosa za zdravstveno osiguranje. U Republici Češkoj, ako postoji ograničenost sirovina za kvalitetno obavljanje posla, zaposlenoj osobi se osigurava naknada u iznosu od 80% prosječne plaće. Valja napomenuti kako Republika Češka zaposlenoj osobi u poduzeću isplaćuje naknadu zarade u iznosu od 60% prosječne plaće u slučaju smanjene potražnje proizvoda ili usluga koje to poduzeće obavlja. Slično provodi i Republika Slovačka, zaposlenim osobama u poduzećima čije je poslovanje privremeno zaustavljeno, Vlada će nadoknaditi 80% zarade. Republika Češka usvojila je program podrške zapošljavanju pod nazivom "Antivirus"

pod kojim se podrazumijeva djelomična naknada ukupnih troškova zarada na koje zaposleni imaju pravo putem refundacija (Istraživački centar, 2020).

U Republici Slovačkoj, u vrijeme pandemije koronavirusa, u slučaju prelaska na drugo radno mjesto istog poduzeća, zaposlena osoba ima pravo na dodatak najmanje u iznosu njegove prosječne plaće koju je primao prije prelaska na novo radno mjesto. Republika Slovačka isplaćuje naknadu za bolovanje koja iznosi 55% dnevne osnovice koja se koristi u izračunavanju naknade za bolovanje. Nadalje, mijenjaju se uvjeti dodatka za njegu djeteta do 10 godina. Sada pravo na dodatak za njegu djeteta imaju roditelji djece do 11 godina ili do 18 godina ako dijete ima dugoročne zdravstvene probleme (Europska komisija, 2020e).

Republika Hrvatska uvela je potpore za očuvanje radnih mjesta za sektore koji su najviše pogođeni pandemijom koronavirusa. Donesena je mjera koja sufinancira trošak plaće u iznosu od 3.250,00 HRK po zaposlenoj osobi. Navedeno se odnosi na mjesec ožujak, a za mjesec travanj i lipanj, taj je iznos povećan na 4.000,00 HRK. Trošak koji se odnosi na mirovinsko i zdravstveno osiguranje, podmiruje se iz državnog proračuna. Država ujedno preuzima plaćanje doprinosa na neto iznos od 4.000,00 HRK, i to 1.460,00 HRK te će ukupna subvencija po radniku iznositi 5.460,00 HRK. Za stalne sezone produženo je vrijeme mirovinskog osiguranja i prava na novčanu pomoć, a produžuje se za vrijeme trajanja ovih izvanrednih okolnosti. Navedeno se odnosi na djelatnosti koje u godini imaju razdoblja smanjenog obujma posla zbog sezonalnosti, ponajprije se to odnosi na sektor turizma i ugostiteljstva (Vlada RH, 2020).

Mjere koje se odnose na cjelokupno stanovništvo

Republika Češka izmijenila je određene uvjete za ostvarivanje prava i dodjeljivanje dječjeg doplatka i stambenog dodatka, te prilagodila postojeće uvjete za povećanje dodatka za njegu. Nadalje, roditelji čija su djeca mlađa od 13 godina, primaju naknadu za njegu bolesnog djeteta tijekom čitavog trajanja izvanrednih mjera vezanih uz COVID-19. Osobe koje brinu o osobama s invaliditetom naknadu mogu zatražiti retroaktivno sve do dana kada su počele posebne mjere vezane uz COVID-19. U Republici Češkoj, fizičkim i pravnim osobama omogućena je odgoda plaćanja rate kredita ili hipoteke na tri ili šest mjeseci, navedeno se odnosi na kredite ugovorene prije 26. ožujka 2020. godine. Također, ograničena je kamatna stopa za kašnjenje prilikom plaćanja. U slučaju duga po osnovi potrošačkog kredita,

ograničava se iznos ugovorene kazne zbog neizvršenja duga koji iznosi više od 90 dana. Slično je učinila i Republika Slovačka, omogućena je odgoda plaćanja kreditnih obveza za najviše 3 mjeseca za sve ostale fizičke i pravne osobe (sve osim banaka). Bankama se pruža mogućnost odgode plaćanja kreditnih obveza za najviše 9 mjeseci. Republika Slovenija omogućila je odgodu plaćanja obveza iz kreditnih ugovora u trajanju od godinu dana. Navedeno se odnosi na fizičke osobe, poduzeća, samozaposlene osobe, razne udruge i institucije, te na poljoprivredna gospodarstva (Europska komisija, 2020c; Istraživački centar, 2020).

Republika Hrvatska povećala je beskontaktno plaćanje sa 100 HRK na 250 HRK. Bitno je spomenuti kako je većina zemalja prakticirala rad od kuće ili je uvedena promjena radnog vremena (Vlada RH, 2020). Republika Slovenija uvela je jednokratni dodatak solidarnosti za umirovljenike: 300 eura za umirovljenike čija je mirovina manja od 500 eura, 230 eura za umirovljenike čije mirovina iznosi između 500,01 i 600 eura, te 130 eura za umirovljenike čija mirovina iznosi između 600,01 i 700 eura. Republika Hrvatska također je uvela jednokratnu naknadu umirovljenicima. Republika Slovenija smanjila je cijenu električne energije kućanstvima, a za mjesec ožujak korisnici su oslobođeni plaćanja ove naknade. Republika Slovenija donijela je odluku o povećanju dodatka za velike obitelji. Dodatak za velike obitelji povećava se za 100 eura za obitelji s troje djece, te za 200 eura za obitelji sa četvero i više djece. Nadalje, Republika Slovenija osigurala je jednokratnu naknadu solidarnosti za ranjive skupine u iznosu od 150 eura, kao i jednokratnu naknadu solidarnosti u iznosu od 150 eura svim osobama koje inače ostvaruju pravo na socijalnu pomoć (Istraživački centar, 2020).

Republika Poljska također je uvela mjere koje se odnose na cjelokupno stanovništvo, npr. produžuje se razdoblje za primanje dodataka za brigu o djeci, potvrda o invalidnosti može se dobiti bez obavljenog pregleda, dovoljna je važeća medicinska dokumentacija, zatim uspostava telefonskih linija za komunikaciju između pacijenata i doktora. Navedeno provodi i Republika Hrvatska kako bi se smanjio socijalni kontakt, te spriječilo širenje koronavirusa (Nakić, 2020).

Mjere koje se odnose na poljoprivrednike

Ako je poljoprivrednik u Republici Poljskoj zaražen koronavirusom, za svaki dan koji nije u mogućnosti obavljati svoj posao ima pravo na naknadu za spriječenost u radu. Naknada se može koristiti najviše 14 dana koliko

traje mjera samoizolacije. Osobe koje završe u samoizolaciji moraju to pismenom izjavom javiti poslodavcu kako bi ostvarili pravo na naknadu. Slično tome uvela je i Republika Slovenija, poljoprivrednici koji su oboljeli od koronavirusa imaju pravo na naknadu zbog spriječenosti u radu, naknada iznosi 80% minimalne zarade. Poljoprivrednici Republike Slovenije imaju mogućnost umanjavanja ili otpis obveze uplaćivanja doprinosa za mirovinsko osiguranje. Postoji mogućnost odgode obveze uplate doprinosa za socijalno osiguranje. Republika Slovenija osigurala je svojim poljoprivrednicima pravo na osnovni mjesečni prihod u iznosu od 350 eura za ožujak, te 700 eura za travanj i svibanj (Istraživački centar, 2020).

Europska komisija (2020c) izvještava o odobrenim potporama poduzećima u poljoprivrednom sektoru, kao i poduzećima koja se bave proizvodnjom hrane u Češkoj. Tako je primjerice 7. srpnja 2020. godine odobren iznos od približno 370 milijuna eura. Izravna potpora bit će otvorena za sva poduzeća koja djeluju u sektoru primarne poljoprivredne proizvodnje te za proizvođače hrane i hrane za životinje. Očekuje se kako će ovu mjeru koristiti između 12 000 i 20 000 poduzeća. Javna potpora, koja će imati oblik izravnih potpora, bit će otvorena za mala i srednja poduzeća koja djeluju u primarnom sektoru poljoprivredne proizvodnje. Cilj je pomoći poljoprivrednim poduzećima u održivosti likvidnosti. Potpora je posebno namijenjena za djelomično smanjenje nepodmirenih obveza poslovnih bankovnih kredita malim i srednjim poduzećima te će pokriti do 50% neplaćenog iznosa kredita. Nadalje, osigurane su izravne potpore, ulaganja u kapital, selektivne porezne olakšice i predujmovi u iznosu do 100 000 eura za poduzeća aktivna u primarnom poljoprivrednom sektoru u Njemačkoj, kao i iznos od 120 000 eura za poduzeća koja se bave ribarstvom i akvakulturom te iznos od 80 000 eura za poduzeća koja se bave svim ostalim sektorima. Primarni cilj je osigurati likvidnost poduzeća (Europska komisija, 2020d). Jednako tako, odobrena su i sredstva za Slovačku (Europska komisija, 2020e).

Republika Hrvatska također pomaže svojim poljoprivrednicima. Mjere su usmjerene na osiguranje likvidnosti, odnose se na postojeće razine zaposlenosti poljoprivrednika, ribara i drvno-prerađivačkog sektora. Spomenute mjere iznose oko 400 milijuna kuna. Valja spomenuti i mjere za odgodu plaćanja dospjelih obveza Hrvatskim šumama za drvene sortimente, mjeru odgode plaćanja zakupnine i koncesijskih naknada za poljoprivredno zemljište kao i za sektor ribarstva. Aktivirana je i digitalna tržnica gdje se odvija prodaja poljoprivrednih i prehrambenih proizvoda. Digitalna tržnica

podrazumijeva razmjenu dobara između domaćih poljoprivrednika i javnih naručitelja. Isto tako, donesena je odluka o otkupu viškova mlijeka od malih mljekara koji imaju godišnji obuhvat otkupljenog i prerađenog mlijeka do 14 milijuna litara. Otkupom viškova mlijeka od malih mljekara osigurava se nesmetana daljnja proizvodnja mlijeka na farmama gdje vlasnici imaju ugovor o proizvodnji i isporuci mlijeka malim mljekarama. Republika Hrvatska provodi mjere financirane uz pomoć ESIF sredstava koje provodi HAMAG-BICRO. Na taj se način povećava alokacija za financijski instrument ESIF Mikro zajmovi za obrtna sredstva, a smanjuju se kamatne stope na investicijske kredite, te se povećava maksimalna stopa jamstava za ESIF pojedinačna jamstva za kredite za obrtna sredstva sa 65% na 80% glavnice kredita. Ova mjera uključuje i moratorij na sve rate EISF zajmova, te zajmova za poljoprivredu i ruralni razvoj, do 31. prosinca 2020. produžuje se otplata roka korištenja zajmova za koje je izdano jamstvo. Donesena su i dva nova financijska instrumenta, COVID-19 zajam za obrtna sredstva i Mikro zajam za ruralni razvoj. COVID-19 zajmom za obrtna sredstva omogućuje se dodatna likvidnost mikro, malim i srednjim poduzetnicima koje je pogodila kriza uzrokovana koronavirusom. Zajmovi iznose do 750.000 kuna za obrtna sredstva, kamatna stopa iznosi 0,25%. Maksimalan rok otplate iznosi 5 godina. Mikro zajam za ruralni razvoj obuhvaća mala poduzeća koja se bave poljoprivrednim, prerađivačkim i šumskim sektorom. Navedeni zajam iznosi između 1.000 i 25.000 eura, a rok otplate je do 3 godine uz kamatnu stopu 0,5% (Vlada RH, 2020).

4. ZAKLJUČAK

U ovom se radu donosi pregled mjera pomoći uslijed pandemije COVID-19 u odabranim zemljama članicama EU. Očuvanje zdravlja kao primarni cilj zemalja, prvo je rezultirao tzv. *lockdownom* ili zaključavanjem, a nastavljene su stroge mjere socijalnog distanciranja, karantene, rada od kuća i slično. Navedeno je rezultiralo narušenim ekonomskim kružnim tokom, što je dovelo do simultanih šokova u agregatnoj ponudi i potražnji. Osim navedena dva šoka, prisutan je i šok očekivanja. Brojke pokazuju da je BDP počeo padati, a u istom smjeru počela se kretati i zaposlenost. Za sada je otežano zbrajati dobitnike i gubitnike ove zdravstvene krize, budući da pandemija još traje, a posljednjih su dana brojke novozaraženih opet u blagom porastu.

Europska unija ubrzo je predložila set mjera za oporavak gospodarstva iz najrazličitijih sektora, a pritom je snažnu financijsku potporu iskazala i zemljama koje su usmjerile likvidnost prema stanovništvu. Republika Hrvatska predstavila je Nacionalni plan oporavka i otpornosti čime je ostvarila pravo na financijsku omotnicu u iznosu od 6,3 milijardi eura. Dodatno opterećenje u pandemiji COVID-19 leži u činjenici da je Republika Hrvatska u tom razdoblju iskusila i dva snažna potresa koji su prvotno otežali provođenje mjera zaštite, a u budućnosti će dodatno opteretiti javne financije.

U radu su razmatrane mjere koje pojedine države članice provode kako bi zaštitile svoja gospodarstva od negativnog utjecaja pandemije virusa COVID-19. Mjere koje su razmatrane odnose se na mala poduzeća, samozaposlene osobe i start-upove, zatim mjere koje se odnose na srednja i velika poduzeća, mjere za poduzetnike, mjere koje se tiču zaposlenih osoba, a razmatrane su i mjere koje se odnose na cjelokupno stanovništvo pojedinih zemalja članica, te mjere za poljoprivrednike. Zemlje analizirane u radu su: Savezna Republika Njemačka, Republika Češka, Republika Poljska, Republika Slovačka, Republika Slovenija i Republika Hrvatska. Većina spomenutih zemalja odgađa plaćanje doprinosa za zdravstveno i mirovinsko osiguranje, te odgađaju rok za predaju godišnjih financijskih izvještaja. Poduzećima se nastoji pomoći u održivosti likvidnosti putem raznih subvencija, doprinosa, zajmova, potpora i pogodnijih kredita. Zaposlenici su uglavnom obavljali svoj posao od kuće, ako imaju uvjete za to, a zaposlene osobe koje završe u izolaciji imaju pravo na novčanu naknadu zbog nemogućnosti obavljanja posla.

Zaključno, nositeljima ekonomske politike slijedi izazovno razdoblje u kojem će biti potrebno donositi makroekonomske mjere koje će trebati moći uklopiti s mjerama donesenima u industrijskoj, trgovinskoj i socijalnoj politici. S ekonomske strane gledano, što dulje pandemija bude trajala, bit će potrebne i veće intervencijske politike (i monetarne i fiskalne) kako bi se ublažile negativne posljedice šoka ponude na zaposlenost, produktivnost, a onda i domaći proizvod. Nadalje, potrebno je osigurati transparentno i sveobuhvatno dijeljenje informacija i redovitu komunikaciju između nositelja ekonomske politike i ostalih ekonomskih agenata. Drugim riječima, potrebno je razviti učinkovit mehanizam s niskim opterećenjem za vlade i partnere iz privatnog sektora za razmjenu informacija o situaciji i opskrbi proizvoda na tržištu.

LITERATURA

AHK (2020). Covid-19: German Federal Support Measures. *Njemačko-hrvatsko industrijska i trgovinska komora*. [Online] Dostupno na: <https://kroatien.ahk.de/hr/info-centar/translate-to-hrvatski-aktuelles-zum-coronavirus> [Pokušaj pristupa 29. 7. 2021.].

Anderton, R. et al. (2020). The Impact of the COVID-19 Pandemic on the Euro Area Labour Market. ECB Economic Bulletin, Issue 8/2020.

Čavrak, V. (2020). Makroekonomija krize COVID-19 i kako pristupiti njenom rješavanju. EFZG Working Paper Series 2003, Faculty of Economics and Business, University of Zagreb. [Online] Dostupno na: <https://hrcak.srce.hr/236781> [Pokušaj pristupa 30. 9. 2021.].

Europska komisija (2020a). State Aid: Commission Adopts Temporary Framework to Enable Member States to Further Support the Economy in the COVID-19 Outbreak. [Online] Dostupno na: https://ec.europa.eu/commission/presscorner/detail/en/ip_20_496 [Pokušaj pristupa: 20. 8. 2021.]

Europska komisija (2020b). State Aid: Commission Approves German Fund to Enable up to €500 Billion of Liquidity and Capital Support to Enterprises Affected by the Coronavirus Outbreak. [Online] Dostupno na: https://ec.europa.eu/commission/presscorner/detail/en/ip_20_1280 [Pokušaj pristupa: 10. 9. 2021.]

Europska komisija (2020c). State Aid: Details of Czechia's Support Measures to Help Citizens and Companies During the Significant Economic Impact of the Coronavirus Pandemic. [Online] Dostupno na: https://ec.europa.eu/info/live-work-travel-eu/coronavirus-response/jobs-and-economy-during-coronavirus-pandemic/state-aid-cases/czechia_en [Pokušaj pristupa: 10. 9. 2021.]

Europska komisija (2020d). State Aid: Commission Approves German Fund to Enable up to €500 Billion of Liquidity and Capital Support to Enterprises Affected by the Coronavirus Outbreak. [Online] Dostupno na: https://ec.europa.eu/commission/presscorner/detail/en/ip_20_1280 [Pokušaj pristupa: 10. 9. 2021.]

Europska komisija (2020e). Details of Slovakia's Support Measures to Help Citizens and Companies During the Significant Economic Impact of the Coronavirus Pandemic. [Online] Dostupno na:

https://ec.europa.eu/info/live-work-travel-eu/coronavirus-response/jobs-and-economy-during-coronavirus-pandemic/state-aid-cases/slovakia_en
[Pokušaj pristupa: 10. 9. 2021.]

Eurostat (2021). Database.

Grdović Gnip, A. (2011). Discretionary Measures and Automatic Stabilizers in The Croatian Fiscal Policy. *Ekonomika istraživanja* 24 (3), str. 44-74.

Hernandez de Cios, P. i Moral-Benito, E. (2016). Fiscal Multipliers in Turbulent Times: The Case of Spain, *Empirical Economics*, Vol. 50, pages 1589-1625.

Hrvatski zavod za zapošljavanje (2020). *Donesene nove mjere za očuvanje radnih mjesta i reaktivirane mjere aktivnog zapošljavanja*. [Online] Dostupno na: <https://www.hzz.hr/novosti-priopcenja/nove-mjere-samozapostljavanje-skracenje-radnog-vremena-i-ocuvanje-radnih-mjesta-za-mikropoduzetnike.php> [Pokušaj pristupa 9.10. 2021.].

Istraživački centar Skupštine Crne Gore (2020). Komparativni pregled: mjere za ublažavanje negativnih posljedica Covid-19 na društvo i ekonomiju u pojedinim zemljama. [Online] Dostupno na: http://arhiva.skupstina.me/images/dokumenti/biblioteka-i-istrazivanje/2020/Mjere_za_ubla%C5%BEavanje_negativnih_posljedica_COVID-19_na_dru%C5%A1tvo_i_ekonomiju_u_pojedinim_zemljama.pdf [Pokušaj pristupa 29. 7. 2021.].

Ministarstvo rada, mirovinskoga sustava, obitelji i socijalne politike (2020). *Koronavirus.hr*. [Online] Dostupno na: <https://www.koronavirus.hr/ministarstvo-rada-i-mirovinskog-sustava/119> [Pokušaj pristupa 9. 10. 2021.].

Nakić, V. (2020). Promjene u obiteljskoj medicini u epidemiji COVID-19. *Medicus*, Vol. 29, No. 2 COVID-19, str. 275-282.

Our World in Data (2021). Database. Oxford Martin School. Dostupno na: <https://ourworldindata.org/grapher/covid-stringency-index?tab=chart&time=2020-01-22..2021-01-12&region=Europe&country=POL~CZE~DEU> [Pokušaj pristupa 08.10. 2021.].

Praščević, A. (2020). Ekonomski šok pandemije COVID-19 – prekretnica u globalnim ekonomskim kretanjima. *Ekonomske ideje i praksa*, Vol. 37, pp. 7-22.

Rogić Dumančić, L., Bogdan, Ž. i Raguž Krištić, I. (2020). Utjecaj COVID-19 krize na hrvatsko gospodarstvo // *Ekonomska politika Hrvatske u 2021.: Hrvatska poslije pandemije* / Tica, Josip; Bačić, Katarina (ur.). Zagreb: Hrvatsko društvo ekonomista, str. 121-163.

Surico, P. i Galeotti, A. (2020). *The Economics of a Pandemic: the Case of Covid-19*, London: London Business School.

Šimović, H. i Deskar-Škrbić, M. (2013). Dynamic Effects of Fiscal Policy and Fiscal Multipliers in Croatia. *Zbornik EFRI*, 31 (1), str. 55-78.

Vlada RH (2020). *Program konvergencije Republike Hrvatske za 2020. i 2021. godinu*. [Online] Dostupno na: <https://vlada.gov.hr/UserDocsImages/2016/Sjednice/2020/Travanj/227%20sjednica%20VRH/Novi%20direktorij/227%20-%2020%20Program%20konvergencije%20Republike%20Hrvatske%20za%202020.%20i%202021.%20godinu.pdf> [Pokušaj pristupa 29. 7. 2021.].

Zahradnik, P., Palmieri, S. i Dirx, J. (2020). Prijedlozi EGSO-a za obnovu i oporavak nakon krize uzrokovane COVID-om 19: „EU se treba voditi načelom da je zajednica koja dijeli zajedničku sudbinu”, *Europski gospodarski i socijalni odbor*. [Online] Dostupno na: http://www.sssh.hr/upload_data/site_files/rezolucija_egso-a_06_2020_covid.pdf [Pokušaj pristupa 15. 7. 2021.].

COMPARATIVE ANALYSIS OF COVID-19 SUPPORT MEASURES IN SELECTED EU MEMBER STATES

Abstract

At the end of 2019 the coronavirus (COVID-19) pandemic emerged and caused numerous changes in the global economies, and therefore changes in people's lives and habits. In a short time, the coronavirus as a health threat has become a generator for the development of the economic crisis worldwide. Virus defense measures, primarily "the lockdown", have prevented the normal functioning of economies, leading to shocks in aggregate supply and demand, as well as expectations. Almost all European countries brought in certain measures to prevent the uncontrolled spread of the virus. This paper examines the impact of the new coronavirus pandemic on selected macroeconomic indicators in the Republic of Croatia and in selected EU Member States. The aim is to investigate the measures introduced by individual countries in order for the COVID-19 pandemic not to have severe consequences on the selected countries' economies. The measures that are considered refer to small enterprises, self-employed persons and start-ups, as well as measures related to medium and large enterprises, measures for entrepreneurs, measures concerning employed persons, and measures related to the overall population of the selected Member States. Furthermore, measures related to the public sector of selected countries and measures for farmers were considered. The selected countries analyzed in this paper are: the Federal Republic of Germany, the Czech Republic, the Republic of Poland, the Slovak Republic, the Republic of Slovenia and the Republic of Croatia. It should be kept in mind that the COVID-19 pandemic is not over yet, and the final consequences of the pandemic will be discussed only once it is completely contained. The further development of the situation depends on the epidemiological situation, in particular on the emergence of new variants of the virus and the ability of economies to adapt to new conditions of greater uncertainty, as well as new challenges such as green transition and digitalization.

Keywords: COVID-19, Croatia, EU, aid measures, macroeconomic consequences.

JEL klasifikacija: E31, F31

Pregledni rad

KOMPARATIVNA ANALIZA INFLACIJE U POSTCOVID RAZDOBLJU ZA HRVATSKU I EUROZONU – MOŽE LI SE OCIJENITI PROBLEMATIČNOM?

Željko Bogdan*

SAŽETAK

Od recentne krize gospodarstva i Hrvatske i eurozone imala su iskustvo jako male, a ponekad i negativne inflacije u uvjetima kad su kamatne stope na tržištu novca bile jako blizu nuli. U ekonomskoj teoriji to je poznato kao situacija koja uvelike usporava oporavak jer sprečava pad realne kamatne stope. Početnu fazu recentne krize (2008. – 2010.) u Hrvatskoj karakterizira snažno smanjenje inflacije koja je i negativna između srpnja 2015. i studenoga 2016. godine, a potom pozitivna do početka Covid krize. U pandemiji 2020. razina cijena opada, ali pozitivna dinamika inflacije 2021. godine ulijeva zabrinutost. Podaci za kolovoz 2021. godine pokazuju inflaciju od 3,1% kojoj najviše pridonose cijene energije i cijene prehrane. Zaključci rada pokazuju da je inflacija u Hrvatskoj u dominantnoj mjeri posljedica većih troškova, ali se ni učinak potražnje, naročito u zadnjih desetak godina, ne može posve isključiti.

Rad je također obuhvatio i čimbenike koji utječu na inflaciju u našim važnim vanjskotrgovinskim partnerima (tj. članicama eurozone) s naglaskom na pandemijsku krizu. Polazeći od važnosti stabilnog tečaja,

* Izv. prof. dr. sc. Željko Bogdan, Ekonomski fakultet Sveučilišta u Zagrebu (e-mail: zbogdan@efzg.hr).

veća inflacija u Hrvatskoj u usporedbi s eurozonom, uzrokuje realnu aprecijaciju i narušava cjenovnu konkurentnost koja je dominantan dio ukupne konkurentnosti našega gospodarstva. Ipak, tijekom 2021. godine inflacija u Hrvatskoj je neznatno veća od one u eurozoni. Osim vanjske trgovine važno je istaknuti i ulogu banaka iz eurozone koje dominiraju u vlasništvu nad aktivom hrvatskog bankarskog sektora. Preko njih se i aktivnosti Europske središnje banke (ECB) za poticanje inflacije makar posredno prelijevaju i na gospodarska zbivanja u Hrvatskoj. Mjere ECB-a pomogle su da Hrvatska i u trenutnoj krizi nastavi s manjim rashodima za kamate. Najave iz ECB-a sugeriraju da će se s rastom inflacije smanjiti monetarna ekspanzija, ali da prije 2023./2024. godine ne očekujemo rast kamatnih stopa.


Ključne riječi: BDP deflator, indeks potrošačkih cijena, indeks proizvođačkih cijena u industriji, konkurentnost.

1. UVODNA RAZMATRANJA

U posljednjih desetak godina gospodarstva eurozone i Hrvatske bila su suočena sa smanjivanjima stope inflacije naročito od kraja 2013. do kraja 2016. godine kada se spustila na rekordno niske razine (slika 1.). U eurozoni se u tom vremenu najčešće kreće između 0 i 1%¹ uz povremena razdoblja s negativnim vrijednostima. Inflacija u Hrvatskoj bila je i manja te je od druge polovice 2015. i kroz cijelu 2016. deflacija bila izraženija i između ožujka i kolovoza 2016. godine bila je oko 1%. Pandemija ponovno spušta inflaciju na rekordno niske razine.

¹ Sve postotne promjene u članku će se, osim ako nije istaknuto drukčije, iskazivati u odnosu na isto razdoblje prijašnje godine, a ne u odnosu na prethodni mjesec ili kvartal. Iznimka će biti samo efektivni tečaj u uvodu.

Slika 1. Dinamika inflacije u Hrvatskoj i u eurozoni (HICP) od početka 2012. do kolovoza 2021.



Izvor: Eurostat.

Gotovo nulta i negativna stopa inflacije u Hrvatskoj je rijetko koga zabrinjavala osim eventualno uske stručne krugove. Uz nepromijenjene nominalne plaće to omogućuje barem očuvanje postojećeg životnog standarda jer se realne plaće ne bi smanjile. Kretanja inflacije u recentnoj krizi zacijelo su pridonosila i poboljšanoj cjenovnoj konkurentnosti domaćih proizvoda. Naime, tijekom zadnjih 6 – 7 godina inflacija u Hrvatskoj je često niža nego u eurozoni, kao našim najvažnijim vanjskotrgovinskim partnerima. Uz nepromijenjen nominalni tečaj, a imajući u vidu strukturu našeg robnog izvoza, to bi sigurno pridonosilo poboljšanju naše cjenovne konkurentnosti. Međutim, domaća je valuta do kraja 2014. imala trend deprecijacije nakon kojeg je uslijedila aprecijacija koja je uz oscilacije potrajala do druge polovice 2018. godine otkada je nominalni tečaj relativno stabilan. Očekivano, u prvom *lockdownu* 2020. nominalni efektivni tečaj je deprecirao oko 0,8% (veljača – svibanj), ali je – nakon aprecijacije – do kolovoza 2020. godine ojačao za 2,1% u odnosu na svibanj. Nakon razdoblja deprecijacije koje je potom uslijedilo nominalni tečaj je u siječnju bio oko 0,6% slabiji u odnosu na kolovoz 2020. godine. Aprecijacija nominalnog tečaja koja je trajala od siječnja do lipnja 2021. iznosila je oko 1%. Nadalje slijede blaže deprecijacije tijekom srpnja i kolovoza, ali će vrijeme pokazati jesu li one bile privremene². Snažnije deprecijacije tečaja u

² Rezultati su zasnovani na podacima HNB-a o nominalnom efektivnom tečaju koji prate vrijednost kune naspram košare valuta 22 trgovinska partnera Hrvatske (9 zemalja iz eurozone, 4 članice EU izvan eurozone i 9 zemalja izvan EU). Uzme li se samo 19 članica eurozone za trgovinske partnere, mjesečni podaci Eurostata signaliziraju povremene aprecijacije i deprecijacije koje se zbivaju svaka dva-tri mjeseca.

pandemiji je sprečavala središnja banka jer bi sigurno pridonijele snažnijem padu gospodarstva u drugom kvartalu 2020. godine³.

Pozitivna dinamika inflacije tijekom 2021. godine te same najave poskupljenja izazvale su znatno veću zabrinutost u Hrvatskoj, ali i u eurozoni. Da bi se utvrdilo koliko je ona (ne)opravdana, potrebno je pokušati odgovoriti na nekoliko pitanja. *Prvo* od njih je zašto je jako niska pa i negativna inflacija puno lošija od umjerene inflacije kakva sada postoji u uvjetima niskih (gotovo nultih kamatnih stopa). *Drugo* je koji čimbenici pridonose inflaciji u tijeku pandemije te u vremenu nakon prvog "zatvaranja" (*lockdown*), ali i koji su bili važni zadnjih 10 – 15 godina. *Treće* pitanje je, sad kad je premašena inflacija od 2%, hoće li Europska središnja banka (ECB) promijeniti monetarnu politiku koja bi u bliskoj budućnosti uzrokovala veće kamatne stope i kako će to utjecati na gospodarstva eurozone i Hrvatske.

Odgovoriti na ova pitanja cilj je ovoga rada. Sama definicija inflacije je općepoznata (rast opće razine cijena), ali ono što se mijenja moguće je mjeriti preko više indikatora. Jedna mogućnost je pratiti *BDP deflator* koji je ponderirani prosjek razina cijena svake pojedinačne komponente BDP-a. Stoga će na njega utjecati deflatori izdataka za osobnu potrošnju (*PCE deflator* – engl. *Personal Consumption Expenditure Deflator*), investicije, državnu potrošnju te izvoza i uvoza (koji je negativna komponenta BDP deflatora). *PCE deflatoru* najbliži je i od njega "poznatiji" *indeks potrošačkih cijena* (CPI). Unatoč sličnom obuhvatu i – pokazat će se kasnije – sličnoj dinamici stope promjene, ovo nisu identični indeksi i među njima postoje značajne razlike⁴. Razinu cijena moguće je popratiti i još jednim

³ Uz stabilan tečaj situacija s niskom inflacijom i u domaćoj ekonomiji i u vanjskotrgovinskim partnerima ne odgovara Hrvatskoj zbog strukture (robnog) izvoza. U njoj, naime, dominiraju proizvodi niske i srednje niske tehnološke razine kojima je nužna značajka cjenovna konkurentnost, a tu je važniji realni tečaj. Uz nepromijenjen nominalni tečaj, znatno veća inflacija u eurozoni u odnosu na Hrvatsku potaknula bi vanjskotrgovinsku razmjenu jer bi domaća dobra relativno pojeftinila, a inozemna relativno poskupjela. Ali niska inflacija i u eurozoni i kod nas ne dovodi do značajne realne deprecijacije koja bi potakla izvoz. Domaćim tvrtkama puno su važniji (jedinični) troškovi rada.

⁴ Razlike između ova dva indeksa su višestruke: *prva* proizlazi iz formule jer se *PCE deflator* bazira na Fisherovoj idealnoj formuli, a *CPI* na Laspeyresovu indeksu cijena. *Druga* razlika proizlazi iz činjenice da se u konstrukciji *CPI*-a koristi izvješće o potrošnji kućanstva, a za *PCE deflator* izvješća kompanija. *Treća* ide iz obuhvata uzorka jer *CPI* mjeri promjenu izdataka svih gradskih kućanstava iz vlastitog džepa, a indeks *PCE* mjeri promjenu robe i usluga koje troše sva kućanstva i neprofitnih ustanova koje služe kućanstvima (NPUSK). Zato je moguće i da neke stavke i izdaci u

indikatorom – *indeksom proizvođačkih cijena u industriji* (PPI). Za slučaj Hrvatske zbog niskog udjela (prerađivačke) industrije u ukupnoj bruto dodanoj vrijednosti (BDV) (između 2000. i 2020. godine je prosječno 20,6%, od čega na prerađivačku industriju otpada 16,2%), ovaj indeks možda neće biti najprikladniji ekvivalent opće razine cijena, ali će biti zgodan indikator konkurentnosti domaćega gospodarstva jer otprilike 90% robnog izvoza otpada na prerađivačku industriju.

Odgovoriti na prvo postavljeno pitanje relativno je lagano. Jako niska inflacija je, općenito, možda pogodna za potrošače, ali nepovoljno djeluje na gospodarski život. Dovoljno se sjetiti da na agregatnu potražnju, zapravo, utječe realna kamatna stopa. Uz gotovo nultu nominalnu kamatnu stopu, niska ili negativna inflacija sužava prostor za značajnije smanjenje realne kamatne stope, što produljuje izlazak iz recesije. U takvim atipičnim uvjetima središnje banke najrazvijenijih zemalja posegnule su za nekonvencionalnim monetarnim politikama kojima je cilj bio potaknuti rast očekivane (i stvarne) inflacije. Time bi se značajnije smanjila realna kamatna stopa, što može biti dovoljno za poticanje ekonomske aktivnosti. Korišteni ovih politika sežu u vrijeme Velike krize (1929. – 1933.) i mogu se primijeniti na više načina od kojih je najpoznatije tzv. *kvantitativno popuštanje* (engl. *Quantitative easing*)⁵. Od studenoga 2008. do listopada 2014. američki je FED proveo tri runde programa kvantitativnog popuštanja, dok je četvrta operacija poduzeta u rujnu 2019., dakle neposredno pred pandemijsku krizu 2020. godine. Slične politike primjenjivale su i središnja banka Ujedinjenog Kraljevstva, ali i ECB i neke druge središnje banke razvijenih zemalja. Međutim, ECB je tek u siječnju 2015. godine objavila da kreće u program kvantitativnog popuštanja, ali su i prije postojali programi otkupa obveznica kao odgovor na europsku dužničku krizu.

Odgovaranje na preostala pitanja relativno je zahtjevnije. Za drugo je nužno dekomponirati stopu inflacije da se rasvijetle čimbenici koji su pridonijeli jako niskoj inflaciji u Hrvatskoj i eurozoni u uvjetima Covid krize, ali i u ranijem razdoblju. To je ostavljeno za sljedeću cjelinu ovog rada. Kod trećeg pitanja valja imati na umu da je postupni porast inflacije tijekom

indeksu PCE budu izvan opsega CPI-a. Detaljnije o ovome je moguće vidjeti u U. S. Bureau of Labor Statistics (2011) koji je sažetak teksta McCully, Moyer, & Stewart (2007).

⁵ Ovaj pojam prva je upotrijebila središnja banka Japana 2001. godine. S opisanim problemom niske inflacije (i deflacije) u kombinaciji sa zamkom likvidnosti u recentno vrijeme prvi se suočio Japan tijekom 90-ih godina prošloga stoljeća.

2021. godine stvorio strah da je za eurozonu, ali i Hrvatsku završilo razdoblje niskih kamatnih stopa. Je li taj strah bio utemeljen, te osvrst na dobivene rezultate kao i pregled radova kojima se može objasniti silazni trend inflacije u eurozoni (ali i Hrvatskoj) tema su trećeg dijela. Četvrti dio su zaključna razmatranja.

2. ANALIZA KRETANJA INFLACIJE U HRVATSKOJ I U EUROZONI

Kada u poslovnim ciklusima istodobno postoje šokovi ponude i potražnje, u utvrđivanju dominantnog šoka može pomoći kretanje razine cijena. Iz osnovne makroekonomske analize kratkog i srednjeg roka koja se izučava na studijima ekonomije poznato je da smanjenje agregatne potražnje dovodi do manje razine cijena (klasični AS-AD model) ili manje inflacije (prilagodbe modela srednjeg roka tako da se, umjesto razine cijena, koristi inflacija). Nasuprot tome, veći (manji) troškovi (obično cijene energije) povećavaju (smanjuju) inflaciju (šok ponude). Naravno, u stvarnosti su često različiti šokovi ispremiješani pa djeluju istodobno. Jasno je da bi u takvim okolnostima pozitivan šok potražnje u kombinaciji s negativnim šokom ponude (veći troškovi) trebao dovesti do rasta (ili ubrzavanja rasta) razine cijena. Dva pozitivna šoka bi mogla djelovati na njezino smanjenje (ili usporavanje rasta), dok je konačan efekt negativnih šokova na cijene nepoznat⁶. Postojeću pandemijsku krizu može se povezati s više šokova jer je tvrdi *lockdown* onemogućio proizvodnju i potražnju (istodobni negativni šokovi ponude i potražnje), ali su 2020. godine bili i manji troškovi energije.

Analizu razine cijena počinje se dekomponiranjem BDP deflatora primjenom ove formule:

$$P = P_C \frac{C}{Y} + P_I \frac{I}{Y} + P_G \frac{G}{Y} + P_X \frac{X}{Y} - P_{IM} \frac{IM}{Y}. \quad (1)$$

Lijevo u (1) je deflator BDP-a, a desno njegove komponente koje proizlaze iz osobne potrošnje, investicija, državne potrošnje te izvoza i uvoza. Prva, tj. komponenta osobne potrošnje definira se kao umnožak PCE deflatora (P_C) i omjera realne osobne potrošnje i realnog BDP-a (C/Y). Njezin porast podrazumijeva porast PCE deflatora i/ili C/Y . Ako C/Y opada, porast

⁶ U klasičnom AS – AD modelu negativni šok potražnje smanjuje dohodak, ali i razinu cijena. Ako je on popraćen i negativnim šokom ponude, npr. rastom cijena energenata, onda će smanjenje dohotka biti snažnije, ali će smanjenje razine cijena biti znatno slabije ako ga uopće i bude.

komponente osobne potrošnje je moguć uz rast PCE deflatora. Komponente ostalih sastavnica BDP-a također se definiraju umnoškom zasebnog deflatora i odnosa realne vrijednosti te komponente i realnog BDP-a (skraćeno "realni omjer"⁷). Među njima jedino se uvozna komponenta javlja s negativnim predznakom, što znači da njezin porast, *ceteris paribus*, pridonosi smanjenju ukupnog deflatora. Dakle, porast uvoznog deflatora ili realnog omjera uvoza će smanjivati P. Pojedinačne deflatore i realne omjere prikazuje slika 19. u Dodacima.

BDP deflatori su dekomponirani na slici 2., a sastavnice stupića (tj. pojedinačni deflatori i realni omjeri) su na slici 19. u Dodacima. Prije 2009. godine sve komponente deflatora rastu jer rastu pojedinačni deflatori s iznimkom promjene zaliha. Dodatno su porastu komponenti investicija, robnog izvoza i ukupnog uvoza pridonosili i povećanja njihovih realnih omjera. Za druge sastavnice BDP-a realni se omjer smanjivao (državna potrošnja, izvoz usluga nakon 2000.) ili je bio promjenjiv (osobna potrošnja) ali nije sprečavao porast njihovih komponenti u deflatoru.

U recentnoj krizi odnosi se ipak mijenjaju. Ukupan deflator raste od 2008. do 2012. te nakon 2016., a u međuvremenu stagnira. Razloge tome otkrivaju kretanja komponenti osobne potrošnje (rast do 2013., smanjenje 2013. – 2016., rast nakon 2016.), investicija (pad 2008. – 2010., stagnacija 2010. – 2016., rast nakon 2016.), državne potrošnje (rast do 2009., a onda stagnacija do 2019. i porast 2020.), izvoza roba i usluga te uvoza (pad 2009., a potom kontinuirani rast osim 2020. za izvoz usluga⁸). Dakle, porastu deflatora (2008. – 2012.) najviše su pridonijeli osobna potrošnja te izvoz. Stagnacija deflatora proizlazi podjednako iz svih komponenti domaće potražnje, a pozitivan utjecaj izvoza roba i usluga bio je približno jednak negativnom utjecaju uvoza. Nakon 2016. rast deflatora omogućuju sve komponente osim državne potrošnje i uvoza. Iz slike 19. još proizlazi da doprinosi komponenti osobne potrošnje, investicija te uvoza uglavnom proizlaze iz promjena realnih omjera. Kod izvoza usluga izražen je pozitivan utjecaj i deflatora i realnog omjera, dok je kod izvoza roba važniji realni omjer budući da se deflator izvoza robe uglavnom smanjivao. Za državnu potrošnju međudjelovanje deflatora i realnog omjera bilo je takvo da je omogućilo stagnirajući utjecaj komponente državne potrošnje na ukupan deflator.

⁷ Radije se koristi termin "realni omjer", a ne udio jer vrijedi $\frac{C}{Y} + \frac{I}{Y} + \frac{G}{Y} + \frac{X}{Y} - \frac{IM}{Y} \neq 1$. Veći realni omjer jedne od komponenti (npr. porast C/Y) obično smanjuje realni omjer druge komponente.


⁸ Koronakriza 2020. godine značajno se negativno odrazila na komponentu izvoza usluga.

Odnos među komponentama deflatora mogao se iskazati i relativno, tj. diobom (1) s P:

$$1 = \frac{P_C C}{P Y} + \frac{P_I I}{P Y} + \frac{P_G G}{P Y} + \frac{P_X X}{P Y} - \frac{P_{IM} IM}{P Y} \quad (2)$$


Svaki pribrojanik s desne strane odgovara udjelu odgovarajuće komponente deflatora u ukupnom deflatoru koji je definiran umnoškom realnog omjera i relativnih cijena. Tako porast udjela komponente osobne potrošnje znači i veći realni omjer za osobnu potrošnju i/ili rast relativnih cijena (brži porast ili sporije smanjenje postotne promjene PCE deflatora u odnosu na ukupni deflator), a slično se interpretiraju i ostali udjeli. Njihova dinamika prikazana je na slici 3. Prema njoj udio komponente C blago se smanjuje iako je i dalje najveći što je i razumljivo jer je C najveća komponenta BDP-a. Udio državne potrošnje se stabilizira nakon 2009., a prije toga se blago smanjuje. Komponenta fiksnih investicija ima rastući udio prije 2009., što je i razumljivo zbog intenzivnog investiranja osobito u infrastrukturu i stanogradnju. Nakon značajnog smanjenja tijekom 2009. i 2010. godine, on ostaje relativno stabilan, ali na nižoj razini u odnosu na pretkrizno vrijeme. Udio komponente izvoza roba iskazuje blagi rast koji je bio privremeno prekinut 2009., dok je snažniji rast udjela izvoza usluga primjetan od 2013. godine, a prije je bio stabilan. Prema formuli (2) kretanje udjela je pod utjecajem realnih omjera, ali i relativnih cijena. A dinamika relativnih cijena vezana je uz odnos stope promjene pojedinačnih deflatora i stope inflacije iz ukupnog deflatora. Stoga je korisno izvršiti i dekompoziciju stope inflacije koja proizlazi iz samog deflatora. Drugi razlog zbog čega je promatranje stope inflacije poželjnije je iz promjenjivosti deflatora pri promjeni bazne godine.

Slika 2. Dekomponiranje BDP deflatora



Izvor: izračun autora.

Slika 3. Udjeli komponenti deflatora u ukupnom deflatoru



Izvor: izračun autora.


Teorijski učinci šokova ostaju nepromijenjeni ako se razina cijena zamijeni stopom inflacije. Negativan šok potražnje u stvarnosti pridonosi manjoj inflaciji koja može postati i negativna (deflacija). Jasno, za konačan zaključak nužan je oprez jer smanjenje inflacije može nastupiti i zbog pozitivnog šoka ponude (npr. pad cijena nafte na svjetskom tržištu, što se odražava i na pad cijena energije) ili negativnog šoka potražnje (pad potražnje za svime pa i energentima, što se odražava na manje cijene energije i manju inflaciju). Slika 4. jasno dočarava da je neovisno o indikatoru razine cijena (deflator BDP-a, CPI, industrijski PPI), stopa inflacije manja nakon 2009. godine, što upućuje ili na dominantan učinak šoka potražnje ili na kombinaciju negativnog šoka potražnje i šoka ponude. Neovisno o indeksu koji se koristi, razina cijena je rastuća u ekspanziji, dok

se u kriznim vremenima inflacija smanjuje ili postaje negativna. Najizraženije smanjivanje razine cijena utvrđeno je kod PPI-a 2009. i 2020., ali su negativna kretanja na godišnjoj razini bila zabilježena i između 2013. i 2016. godine. Godišnji indeksi iskazani preko BDP deflatora ili CPI-a su signalizirali rast razine cijena koji je u vremenu nakon 2009. godine ipak bio usporen. Kad se promatraju godišnji podaci, CPI se između 2014. i 2016. također smanjivao, ali znatno slabije od PPI-a, dok je BDP deflator 2014. i 2015. bio gotovo nepromijenjen, a 2016. godine bio je blago manji.

S teorijske strane snažniju inflaciju u vremenu prije 2009. godine može se dovesti u odnos s pozitivnim šokom agregatne potražnje koji je rezultirao rastom i investicija i osobne potrošnje. S porastom osobne potrošnje razumno je očekivati porast vrijednosti CPI-a. S općenitim porastom ekonomske aktivnosti logično je pretpostaviti i porast vrijednosti BDP deflatora⁹. Pa opet i u tom razdoblju ekonomske ekspanzije prije 2009. godine postoje razdoblja kad je BDP deflator bilježio pad, a CPI rast (2005. – 2007.). Već je upozoreno na različitu dinamiku razine cijena ovisno o indeksu u vremenu nakon 2009. godine kada se koriste godišnji podaci. Upravo ovi različiti rezultati na godišnjim indikatorima zahtijevaju da se pokuša ove postotne promjene dekomponirati kako bi se utvrdili što je na njih najviše utjecalo ili da se frekvencija prebaci na mjesečnu ili kvartalnu razinu. Ovaj drugi pristup će se upotrijebiti za zadnje dvije godine – dakle vrijeme pandemije i vrijeme koje joj neposredno prethodi.

⁹ Jasno, iz klasičnog AS – AD modela je znano i da porast razine cijena ne mora uslijediti iz veće agregatne potražnje, već iz negativnog šoka agregatne ponude. Razumno je pretpostaviti da prije 2009. godine postoje i pozitivan šok potražnje i negativan šok ponude, ali koji je šok dominantan mora se istražiti empirijski. Iako je prema veličini životnog standarda u odnosu na druge postsocijalističke zemlje Hrvatska bila u sredini prije recentne krize, posljedice krize koja je od 2009. do 2014. pogodila naše gospodarstvo svakako su povezane i s ekonomskom i razvojnom politikom koju je Hrvatska provodila do 2009. godine.

Slika 4. Dinamika inflacije u Hrvatskoj između 2001. i 2020. mjerena kao postotne promjene različitih indeksa



Izvor: Eurostat, DZS.

Dekomponiranje inflacije iz BDP deflatora učinjeno je prema sljedećoj formuli (3):

$$\pi_t = \left(\frac{P_C}{P_{t-1}} \frac{C}{Y} - \frac{\$C_{t-1}}{\$Y_{t-1}} \right) + \left(\frac{P_I}{P_{t-1}} \frac{I}{Y} - \frac{\$I_{t-1}}{\$Y_{t-1}} \right) + \left(\frac{P_G}{P_{t-1}} \frac{G}{Y} - \frac{\$G_{t-1}}{\$Y_{t-1}} \right) + \left(\frac{P_X}{P_{t-1}} \frac{X}{Y} - \frac{\$X_{t-1}}{\$Y_{t-1}} \right) - \left(\frac{P_{IM}}{P_{t-1}} \frac{IM}{Y} - \frac{\$IM_{t-1}}{\$Y_{t-1}} \right) \quad (3)$$

pri čemu \$ označava nominalne vrijednosti, a π stopu inflacije. Svaka komponenta deflatora iz (1) deflacionirana je ukupnim deflatorom iz prethodne godine i dodatno korigirana udjelom u BDP-u. Prema (3), uz nepromijenjenu trenutnu razinu cijena, manja prošlogodišnja razina cijena ili udjeli u BDP-u te veći realni omjeri povećavaju današnju inflaciju *ceteris paribus*. Raščlanjena stopa inflacije prikazana je na slici 5., ali je zaključivanje kompliciranije jer pozitivan utjecaj na deflator ne znači nužno i pozitivan utjecaj na inflaciju. Tako će pozitivan (negativan) efekt osobne potrošnje postojati ako je porast PCE deflatora veći (manji) od razlike između realne stope rasta BDP-a i realne stope rasta osobne potrošnje. Slično vrijedi i za ostale komponente osim za uvoz jer je tada utjecaj uvoza na inflaciju negativan¹⁰. Prema slici 5. do recentne krize je negativna

¹⁰ Zaključak se za osobnu potrošnju lako izvodi i dalje poopćava na ostale komponente. Pozitivan doprinos osobne potrošnje na inflaciju, tj. $\frac{P_C}{P_{t-1}} \frac{C}{Y} - \frac{\$C_{t-1}}{\$Y_{t-1}} > 0$ podrazumijeva i $P_C \frac{C}{Y} > \frac{\$C_{t-1}}{\$Y_{t-1}}$. Odatle se neposredno dobije da je $\frac{P_C}{P_{Ct-1}} > \frac{C_{t-1}/Y_{t-1}}{C/Y} = \frac{Y/Y_{t-1}}{C/C_{t-1}}$. Svi ovi verižni indeksi sad se napišu preko stopa rasta (stopa inflacije, stopa rasta BDP-a i stopa rasta osobne potrošnje) $1 + \pi_C > \frac{1+g_Y}{1+g_C}$ gdje je π_C postotna promjena PCE deflatora. Odatle se aproksimacijom neposredno dobije:

$$\pi_C > g_Y - g_C$$

komponenta inflacije bio uvoz, ali se doprinos smanjivao uz oscilacije (pozitivan učinak uvoza zamjetan je tek u godinama značajnijeg smanjenja uvoza, tj. 1998., 2009. i 2020.). Preostale komponente su utjecale na porast inflacije (naročito investicije 1996., 1997. i 2003., osobna potrošnja 1997., izvoz roba 2000., izvoz usluga 1996. i 1997.)¹¹. Uoči recesije 2009. godine inflaciju najviše potiču osobna potrošnja i investicije.

Globalna kriza 2009. godine uzrokuje kontrakciju agregatne potražnje većine razvijenih zemalja, što se odrazilo i na smanjenje njihovih uvoza i turističkih dolazaka. Posljedica toga je i smanjenje izvoza Hrvatske. Smanjuju se također i domaća potražnja (osobna potrošnja i investicije), što smanjuje i uvoz. Posljedica je manji pozitivan (osobna potrošnja) ili negativan utjecaj (investicije¹², ukupan izvoz) na inflaciju. Pozitivno na inflaciju utječu manji uvoz i (veća) državna potrošnja i oni su jači od negativnih faktora pa deflator BDP-a 2009. raste oko 3%, ali manje nego u 2007. (4,1%) ili 2008. (5,55%). 2010. i inflaciji najviše pridonose dva kontraefekta – pozitivan učinak izvoza roba uz negativan investicijski, dok su pozitivni efekti osobne potrošnje i izvoza usluga zanemarivi. Idućih godina slabe doprinosi i drugih komponenti pa se i deflator smanjuje s 1,6% (2011.) na -0,1% (2016.)¹³. Tijekom 2017. i 2018. godine deflator raste iako je najveći pojedinačni doprinos negativan (uvoz). Uz negativan utjecaj uvoza, promjena zaliha (z) dodatno ublažava važan pozitivan utjecaj izvoza usluga pa je porast razine cijena 2019. usporen (1,5%). Koronakrizom 2020. godine deflator dodatno pada na 0,4% ponajprije zbog pada deflatora izvoza usluga unatoč pozitivnom utjecaju drugih komponenti BDP-a.


što je uvjet za pozitivan doprinos osobne potrošnje inflaciji. Postotna promjena PCE deflatora mora biti veća od razlike između realnog rasta dohotka i realnog rasta osobne potrošnje. Na isti se način dobije i uvjet preko kojeg i ostale komponente BDP-a djeluju pozitivno na inflaciju: $\pi_I > g_Y - g_I$, $\pi_G > g_Y - g_G$ i $\pi_X > g_Y - g_X$. Ali uz i $\pi_{IM} > g_Y - g_{IM}$ utjecaj uvoza je negativan.

¹¹ Od drugih komponenti koje povremeno djeluju na smanjenje inflacije valja istaknuti promjenu zaliha, državnu potrošnju (1996., 2000., 2001.) i izvoz usluga (1997., 2002., 2003.).

¹² Negativan utjecaj fiksnih investicija na inflaciju je najviše izražen tijekom 2009. i 2010. godine jer su tada i najviše pale. One su 2010. bile manje za 27,4% u odnosu na 2008. godinu, ali se pad nastavio i u sljedećim godinama premda je bio znatno slabiji. Posljedica je kumulativni pad investicija za 31,6% između 2008. i 2013. godine.

¹³ Ovdje je korisno napomenuti negativan doprinos uvoza koji snažno pada 2009. (za 20,3%), a počinje se oporavljati od 2012. i tek 2017. premašuje vrijednost iz 2008. godine. Međutim, razdoblje od 2012. do 2017. godine je vrijeme prosječnoga godišnjeg rasta uvoza za 7,8%. Istodobno stope rasta dohotka znatno su manje, a deflator uvoza se kreće oko 1. Zbog svega ovog uvoz negativno pridonosi inflaciji između 2011. i 2019. godine.


Slika 5. Raščlamba postotne promjene BDP deflatora prema komponentama BDP-a



Izvor: izračun autora.


Strukturu kvartalnog deflatora u koronakrizi otkriva slika 6. Osobito negativan utjecaj izvoza usluga na inflaciju 2020. godine bio je tijekom drugog i trećeg kvartala zbog izrazite ovisnosti Hrvatske o turizmu. Relativnu kratkoću koronakrize pokazuje inflacija od 3,5% u drugom kvartalu 2021. godine kojoj je dominantno pridonio izvoz iako su i ostale sastavnice BDP-a, s iznimkom državne potrošnje, također imale pozitivan doprinos.

Slika 6. Raščlamba deflatora BDP-a i postotne promjene tijekom koronakrize (2020. – 2021.)



Izvor: izračun autora.

Slika 7. Postotne promjene deflatora osobne potrošnje (PCE deflatora) i indeksa potrošačkih cijena (CPI)




Izvor: Državni zavod za statistiku i obrada autora.

Dok s jedne strane smanjuje deflator BDP-a, poskupljenje uvoza potrošačku košaricu sigurno čini skupljom pa nas više zanima *indeks potrošačkih cijena* (CPI). Dinamika inflacije proizašla iz ovog indeksa ponešto je slična inflaciji PCE deflatora (slika 7.).¹⁴ Slično deflatoru i dinamika indeksa potrošačkih cijena signalizira snažniji porast razine cijena u vremenu prije krize 2009. – 2014. u usporedbi s razdobljem 2014. – 2020. Tijekom predzadnje krize promjena razine cijena još uvijek je bila pozitivna s posebnim naglaskom na 2012. godini kada je postignuta najveća CPI inflacija u promatranom razdoblju. Nakon 2013. slijedi razdoblje najslabije inflacije u Hrvatskoj, a iako se to na samom grafikonu ne može otkriti, još je u posljednjem kvartalu 2013. godine inflacija već pala blizu 0%. Između 2014. i 2016. godine poprima i negativne vrijednosti, što je izrazito nepovoljna situacija za monetarnu politiku. S jedne strane uzak je prostor za manju realnu kamatnu stopu, a s druge strane postoji depozitna i kreditna euroizacija zbog koje je HNB prisiljen sprečavati snažnije deprecijacije kune premda su deprecijacijski pritisci trajali do kraja 2014. godine. U uvjetima slabo promjenjive razine cijena, promjena nominalnog tečaja je ključan čimbenik promjene realnog tečaja koja je važan čimbenik konkurentnosti u gospodarstvima poput hrvatskog. Pa ipak, kada bi i porastao izvoz kao rezultat djelovanja ovih faktora, izgledan je snažan pad domaće potražnje zbog povećanja realne zaduženosti. Tako bi negativna reakcija domaće potražnje kompenzirala dijelom ili u potpunosti pozitivan efekt na vanjskotrgovinsku konkurentnost ako bi ga uopće i bilo (Tkalec,

¹⁴ Serija CPI-a koju objavljuje DZS počinje s 2004. godinom. Prije su se koristili indeksi troškova života i indeksi cijena na malo. Indeksi troškova života od 1998. do 2004. godine usporedivi su s CPI-em.

Vizek, & Verbič, 2014). Razdoblje negativne inflacije trajalo je do 2016., ali ni u razdoblju 2017. – 2020. inflacija – osim 2018. godine – nije prelazila 1%. Utvrđivanje faktora koji su najsnažnije pridonijeli ovim kretanjima ostavljeno je za sliku 20. u Dodacima.

Slika 8. Raščlanjen doprinos cijena hrane u ukupnom CPI-u



Izvor: izračun autora na temelju podataka iz DZS-a.

Na temelju slike 20. možemo zaključiti:


1. Prije krize 2009. jedino se kupnja vozila izdvaja negativnim efektom na potrošačku inflaciju, a on je bio najsnažniji 2005. godine.
2. Kroz gotovo cijelo promatrano razdoblje cijene hrane pozitivno utječu na inflaciju sa izrazito snažnim utjecajem 2005., 2007., 2008., 2011. – 2013. i 2017. godine, ali se izdvaja i nekoliko godina s negativnim efektom (2010., 2014., 2016., 2019.)¹⁵. Prema slici 8. uočava se da svi oblici hrane ne utječu podjednako na ukupnu inflaciju. U pretkrizno vrijeme najvažniji je utjecaj cijena kruha i žitarica koje su između 2004. i 2008. godine porasle za 38,5%. U isto vrijeme značajno su poskupjeli i mlijeko, sir i jaja (32,4%) te ulje i masti (34,9%) iako se veći dio poskupljenja dogodio 2008. godine. Rasle su cijene i drugih oblika prehrane, ali su izdvojeni najvažniji oblici.

¹⁵ Negativan utjecaj cijena hrane 2019. godine na domaću inflaciju bio je relativno slab, a najveći pojedinačni (pozitivan) doprinos imao je duhan.

3. Između 2014. i 2016. inflacija je negativna, ali već u zadnjem kvartalu 2013. godine pada ispod 1%. Doprinosi se ipak razlikuju pa negativnoj inflaciji 2014. (-0,3%) najsnažnije pridonose cijene hrane te odjeće i obuće, ali ovaj negativan efekt značajno ublažavaju pozitivni doprinosi cijena duhana i opskrbe vodom te goriva i maziva. Tijekom 2015. i 2016. godine negativan doprinos ukupnoj inflaciji najčešće je povezan s energetske troškovima (ponajprije gorivom za vozila te cijenama plina za stanove).
4. Oporavak ekonomije koji je započeo potkraj 2014. (tehnički tek sa prvim kvartalom 2015.) i trajao do izbijanja Covid krize pozitivno se odrazio na inflaciju tek u prosincu 2016. godine. Tijekom 2017. i 2018. godine svojim pozitivnim efektom izdvajaju se cijene goriva i maziva. Međutim, 2017. godine puno su važniji pozitivan doprinos cijena hrane, ali i negativan doprinos cijena električne energije. Tijekom 2019. godine više faktora pozitivno utječe na inflaciju, a nešto je izraženiji efekt cijena duhana.
5. Tijekom koronakrize poništavaju se pozitivni i negativni čimbenici pa razina cijena raste 0,1%. Među njima se posebno izdvajaju pozitivan utjecaj cijena prehrane, ali i negativni utjecaji cijena goriva.

Ovdje je osobito korisno istaknuti zašto je tijekom 2015. i 2016. godine, unatoč početku procesa oporavka od dugotrajne krize, rast razine cijena mjeren potrošačkim cijenama još bio negativan. Već je bio naglašen utjecaj troškova energije, a oni su većinom određeni uvjetima na svjetskom tržištu. No ne može se zanemariti ni utjecaj osobne potrošnje koja je 2015. realno rasla oko 0,4%, a 2016. godine 3,1%, što je bilo ispod porasta BDP-a. Razumno je dakle zaključiti da su u obje godine domaću inflaciju dirigirali uvjeti na svjetskom tržištu, ali i da za 2015. godinu valja istaknuti nedostatan oporavak osobne potrošnje.

Slika 9. Raščlanjen doprinos cijena hrane u ukupnom CPI-u 2021.



Izvor: izračun autora na temelju podataka iz DZS-a.


Da bi se promatrao utjecaj Covid krize na potrošačku inflaciju, potrebno je promatrati kretanje inflacije na mjesečnoj razini tijekom 2020. i 2021. godine (slika 21. u Dodacima). Sama kriza Hrvatsku je zahvatila u ožujku 2020., ali prave posljedice su vidljive već u travnju iste godine. Uoči nje u siječnju 2020. godine inflacija je iznosila relativno niskih 2%, a u veljači 1,5%. Značajnije smanjivanje inflacije nastupa u ožujku (0,6%), a od travnja 2020. do siječnja 2021. godine poprima i negativne vrijednosti. Od siječnja do travnja 2020. najsnažniji pozitivni utjecaj na inflaciju imala je prehrana, ali je značajan utjecaj ostao do svibnja 2020. godine. I poslije svibnja njezin utjecaj ostaje pozitivan, ali se smanjuje te od prosinca 2020. do svibnja 2021. godine pridonosi smanjenju ukupne inflacije. I dok se na slici 8. uočava da su u prehrani 2020. najvažnije cijene povrća, prema slici 9. od siječnja do svibnja 2021. godine najvažnije su cijene mesa, a da od lipnja raste značaj cijena ulja i masti te povrća te mlijeka, sira i jaja. Međutim, negativan utjecaj na inflaciju tijekom 2020. godine ponajprije proizlazi iz cijena goriva i maziva te cijena krutih goriva. Taj efekt je postojao od ožujka 2020. do siječnja 2021. godine, ali je bio najizraženiji u vrijeme prvog *lockdowna* (travanj – lipanj 2020.). Tada je zatvaranje pridonijelo smanjenom transportu, što je za posljedicu imalo i pad potražnje za gorivima. Nakon ožujka 2021. godine (posljednji podaci su za rujna) cijene goriva bile su najsnažniji čimbenik koji pridonosi pozitivnoj inflaciji. Međutim, na pozitivnu inflaciju tijekom 2021. godine utječu i duhan, plin, a tijekom ljetne sezone je porastao značaj restorana i hotela, a u srpnju i kolovozu i komunikacije. Iako je znatno oblikuju zbivanja na svjetskom tržištu, pozitivna dinamika inflacije 2021. godine može uputiti i na relativno brz oporavak naše ekonomije. Godišnji pad hrvatskoga gospodarstva 2020.

godine bio je 8%, ali pravu sliku o oporavku daju rezultati drugog kvartala 2021.¹⁶ Projekcije HNB-a upućuju na mogući rast od 6,8% tijekom ove, a 4,4% u idućoj godini (HNB, 2021). Ljetne prognoze Europske komisije su znatno pesimističnije za ovu godinu (5,4%), ali i optimističnije za sljedeću (5,9%) (Europska komisija, ljeto 2021.). U svakom slučaju, obje analize sugeriraju da će tijekom 2022. biti premašena razina BDP-a iz 2019. godine.

Osim potrošačkih cijena, mogu se promatrati i proizvođačke cijene u industriji. Iako sam sektor ukupne industrije otprilike obuhvaća oko petine cjelokupnoga hrvatskoga gospodarstva, one su nam je interesantne iz dva razloga. Prvi je udio proizvoda iz sektora usluga u ukupnoj potrošačkoj košarici koji u Hrvatskoj iznosi oko 25% pa ostatak košarice uglavnom obuhvaćaju različiti proizvodi iz sektora industrije domaćeg ili uvoznog porijekla. Tako se proizvođačke cijene industrije prelijevaju i na potrošačke cijene. Drugi je već istaknut u uvodu – udio prerađivačke industrije u robnom izvozu pa se kretanje cijena prema PPI-u automatski odražava i na cjenovnu konkurentnost našega gospodarstva. Prati li se samo postotna promjena domaćeg PPI-a, tada se o relativnom pogoršanju cijene naših proizvoda može samo suditi uz pretpostavku da se ne mijenjaju inozemni PPI i tečaj. Međutim, u stvarnosti se mijenjaju obje varijable pa je prikladnije promatrati relativne cijene, tj. omjere realnog i nominalnog efektivnog tečaja i njihove postotne promjene.


¹⁶ Realni pad BDP-a od 0,7% u prvom kvartalu 2021. je očekivan jer su se prve posljedice Covid krize mogle osjetiti tek u drugom kvartalu 2020. godine. Preliminarni rezultati za drugi kvartal 2021. upućuju na rast od 16,1% u odnosu na isti kvartal 2020. godine, čemu je najsnažnije pridonio izvoz roba (rast od 35,2%) i usluga (56,3%), dok je državna potrošnja ispodprosječno rasla. Unatoč izvanrednim brojkama, uz prošlogodišnji pad u drugom kvartalu od 14,4%, BDP Hrvatske u drugom kvartalu 2021. je ipak manji za oko 0,6% u odnosu na isti kvartal 2019. godine.

Slika 10. Komponente indeksa proizvođačkih cijena u Hrvatskoj



Izvor: Eurostat.


Slika 11. Komponente indeksa proizvođačkih cijena u Hrvatskoj kad se dekomponiraju potrošačka dobra



Izvor: Eurostat.


Iz slika 10. i 11. proizlazi da najveći dio promjene indeksa proizvođačkih cijena u industriji proizlazi iz cijena energije, a naročito je to očito nakon 2008. godine kada je pretežito zbog njihova kretanja predznak promjene ovog indeksa pozitivan jer druge sastavnice bilježe pad cijena ili izuzetno slab rast. Utjecaj troškova energije potvrđen je i za vrijeme Covid krize (slika 13.), što se može povezati i sa slikom 21. jer se kretanje i potrošačke i proizvođačke inflacije upravo može povezati s troškovima energije. Slika 12. dodatno raščlanjuje dinamiku PPI-a i pokazuje da najvećim dijelom promjene indeksa proizlaze iz podindeksa za srednje nisku tehnologiju, što nije iznenađujuće s obzirom na to da prerađivačku industriju karakterizira srednje niska tehnološka razina (Lovrinčević, 2009), a cijene glavne sirovine su još pod snažnim utjecajem zbivanja na svjetskom tržištu.

Slika 12. Komponente indeksa proizvođačkih cijena u Hrvatskoj prema tehnološkoj razini




Izvor: Eurostat.

Slika 13. Dinamika PPI-a (ukupno tržište) tijekom Covid krize po mjesecima



Izvor: Državni zavod za statistiku.


Slika 14. Relativne cijene bazirane na indeksu proizvođačkih cijena u industriji i njihove postotne promjene



Napomena: Porast relativnih cijena označava promjenu odnosa u korist domaćih dobara.

Izvor: Hrvatska narodna banka.

Slika 15. Cjenovna konkurentnost preko realnog efektivnog tečaja s PPI-em kao deflatorom



Napomena: Porast tečaja označava realnu deprecijaciju.

Izvor: Hrvatska narodna banka.


Slika 14. prikazuje relativnu cijenu domaćih dobara, pri čemu porast relativnih cijena podrazumijeva i njihovo relativno pojeftinjenje. Kada se one pomnože s nominalnim efektivnim tečajem (NEER), dobije se realni efektivni tečaj (REER – deflator PPI) čije je kretanje predloženo na slici 15. NEER je od prvog kvartala 2015. do trećeg kvartala 2019. godine aprecirao i ublažavao relativno pojeftinjenje domaćih dobara. Vrijeme Covid krize popraćeno je blagom deprecijacijom realnog tečaja do ožujka 2021. koja je ipak bila najizraženija u vrijeme strogog zatvaranja gospodarstva (promatrano u odnosu na isti mjesec protekle godine). Iz slike 14. zaključuje se da su tome više pridonijele relativne cijene (omjeri PPI-a), ali je do srpnja 2020. godine utjecala i nominalna deprecijacija.

Praćenje realnog tečaja s prethodnoga grafikona važno je radi analiziranja vanjskotrgovinske konkurentnosti. Budući da su nam najvažniji vanjskotrgovinski partneri članice eurozone¹⁷, smisleno je i za njih pratiti dinamiku potrošačke inflacije. Uz članstvo u EU, tome treba dodati i dominantan udio aktive bankovnog sektora kojeg u Hrvatskoj drže upravo banke iz eurozone. Zato bankovnim kanalom mjere ECB-a utječu na aktivnosti većinskih vlasnika naših banaka. Tako su se niske kamatne stope u eurozoni prevaljivale i u Hrvatsku kojoj je to pomoglo smanjiti izdatke na kamate nakon 2015. godine. Usporedba kretanja stope inflacije u eurozoni i Hrvatskoj već je djelomice bila obrađena u uvodu (slika 1.). Za razliku od

¹⁷ Sigurno približno 50% naše vanjskotrgovinske razmjene otpada na članice ove grupacije, dok preostalih 10-15-ak % naše robne razmjene otpada na članice EU izvan eurozone.


Hrvatske, eurozonska se inflacija kraće zadržava u negativnom području (trivala – I. prosinac 2014. – ožujak 2015.; II. veljača – svibanj 2016.; III. kolovoz – prosinac 2020.). Međutim, velikim dijelom istraženog razdoblja kreće se do 1%, a osobito rijetko prelazi ciljanu razinu od 2% (nakon siječnja 2013. to se dogodilo samo u veljači 2017. (2%) te između svibnja i listopada 2018.). Dekomponiranje ovih kretanja ostavljeno je za sliku 22. u Dodacima. Tijekom 2021. godine inflacija raste i prelazi razinu od 2% (svibanj, srpanj, kolovoz, a po svemu sudeći, i rujan 2021.), ali to ne bi trebalo za eurozonu biti problematično¹⁸. Hoće li zbog ovoga završiti razdoblje relativno niskih kamatnih stopa komentira se u idućem dijelu rada.

Slika 16. Komponente indeksa proizvođačkih cijena u eurozoni



Izvor: Eurostat.

Slika 17. Dinamika PPI-a tijekom Covid krize po mjesecima u eurozoni



Izvor: Eurostat.

¹⁸ Očekuje se rujanska inflacija od 3,4% sa značajnim doprinosom cijena energije (Eurostat, 2021). Za Njemačku se procjenjuje i veća inflacija – od 4,1%, čemu značajno pridonosi i nestašica sirovina. Međutim, porasle su i cijene živežnih namirnica zbog veće potražnje nakon uklanjanja ograničenja – zato što su u krizi mnoge kompanije smanjile opseg svog djelovanja. Koronakriza je poremetila lanac opskrbe (Ehrhardt, 2021).

Na slici 16. su, kao i za Hrvatsku, predložene postotne promjene PPI-a u industriji na godišnjim podacima (2001. – 2020.). Efekti pandemijske krize na mjesečnim podacima ostavljeni su za sliku 17. Osnovni zaključak je sličan hrvatskom – da je proizvođačka inflacija u najvećoj mjeri povezana s cijenama energije. Radi usporedbe isprekidanom linijom prikazana je i promjena cijena za energiju u Hrvatskoj. U vremenu koje je neposredno prethodilo krizi iz 2009. cijene energije u eurozoni su brže rasle od hrvatskih (2005. – 2008.), ali su nakon 2009. godine promjene cijene energije izraženije u Hrvatskoj, pri čemu se razdvajaju razdoblja snažnijeg rasta (2010. – 2012. te 2017. – 2018. i 2021.) i snažnijeg pada (2013. – 2016. i 2019. – 2020.).

3. KOMENTARI REZULTATA I OSVRT NA MOGUĆE FAKTORE NISKE INFLACIJE

Porast inflacije tijekom prvih osam mjeseci 2021. godine i u Hrvatskoj i u eurozoni izazvao je zabrinutost iako je još uvijek na relativno niskoj razini. U rujnu 2021. godine prvi put je izjednačena inflacija iz travnja 2013. (3,3%). Slika 21. u Dodacima otkriva da je to većim dijelom posljedica rasta cijena goriva i maziva. Dok se tu stavku zajedno s duhanom često prihvaća "zdravo za gotovo", puno veću zabrinutost izaziva veći značaj cijena prehrane i mogućnost poskupljenja ogrjeva. Porast cijena plina za kućanstva, koje su i tako pozitivna stavka u inflatornim kretanjima, do kraja ove sezone grijanja je isključen, ali je izgledno njegovo poskupljenje tijekom iduće godine. No i bez iščekivanja poskupljenja plina, rastući značaj prehrane u inflaciji već je bio potvrđen u srpnju i kolovozu, a izgledno je da će se nastaviti i idućih mjeseci. Slika 9. pokazala je da je on dominantno bio povezan s rastom cijena ulja i masti, povrća te mlijeka, sira i jaja premda je zabilježen i pozitivan doprinos ostalih komponenti prehrane s iznimkom voća. Promatrajući na povijesnim podacima slike 20. značajniji udio cijena ulja i masti u ukupnom doprinosu cijena hrane bio je izražen tek 2008. i 2011. godine. Nasuprot tome, cijene mlijeka, sira, jaja te povrća jesu imale značajne udjele, ali, osim 2014. godine, nisu bile dominantne u prehrani. U bliskoj budućnosti može se očekivati da će se ovaj pozitivan trend nastaviti, ali povremeno značajniji njihov udio u prehrani daje za naslutiti i da bi se njihov doprinos mogao stabilizirati.


Predočeno potiče da se pokuša procijeniti je li na inflaciju u Hrvatskoj više djelovao šok potražnje ili šok ponude. Svi prikazani rezultati idu u prilog tome da je inflacija u Hrvatskoj u dominantno troškovne prirode i da je u manjoj mjeri uzrokovana faktorima potražnje iako se ni oni ne mogu u potpunosti isključiti¹⁹.

Naposljetku valja se još jednom osvrnuti na potrošačke cijene u eurozoni koje su tijekom 2021. godine dominantno pod utjecajem cijena goriva i maziva za automobile (slika 22.). Taj zaključak nije iznenađujući s obzirom na snažnu korelaciju između cijena barela nafte i stope promjene HICP-a u vremenu između 2008. i 2021. (HUB_Analize_br. 73, 2021). U svibnju i lipnju 2021. godine cijene energije (goriva, električna energija, plin te tekuća i kruta goriva) otprilike obuhvaćaju oko 60% cjelokupne inflacije iz HICP-a. Prema tim podacima znatno je smanjen udio prehrambenih proizvoda u ukupnoj inflaciji premda su od siječnja do ožujka 2021. godine bili treći po važnosti faktor inflacije nakon cijena goriva i rekreacije.


¹⁹ U tu je svrhu načinjena pojednostavnjena regresijska analiza koja je uvijek potvrđivala pozitivan doprinos deflatora uvoza i nesignifikantan utjecaj osobne potrošnje, ali zbog velikog obujma rada njezin je ispis izostao. Takav je rezultat smislen zbog velike uvozne ovisnosti naše ekonomije. Značajne su bile i promjena PPI-a u energiji te ukupnog PPI-a. Ovi se rezultati mogu povezati kroz cijene fosilnih goriva jer su oni uvozno dobro pa utječu i na uvozni deflator, PPI i na kraju se prevladavaju i na potrošačke cijene. Naravno, fosilna goriva nisu jedina uvozna komponenta, već postoji mnoštvo uvoznih dobara koji su nezaobilazan dio potrošačke košarice.

Slika 18. Distribucija kredita drugih monetarnih financijskih institucija kućanstvima i poduzećima prema namjeni – stanje potkraj razdoblja

KUĆANSTVA



PODUZEĆA



Izvor: Hrvatska narodna banka.

Uvodni dio rada unaprijed je istaknuo silazni trend inflacije u eurozoni premda uz oscilacije, a to se uobičajeno objašnjava fiskalnom i monetarnom politikom. Povijesno niske kamatne stope u ekonomskoj teoriji pozitivno utječu na agregatnu potražnju i razinu cijena. Mogu kreirati i očekivanja o budućem porastu kamatnih stopa i utjecati na prinose na financijskim tržištima. Nakon što je inflacija u kolovozu 2021. procijenjena na oko 3%, Europska središnja banka je objavila da će nastaviti dosadašnju monetarnu

politiku, ali uz ublaženo kupovanje obveznica²⁰. Prema tome, uskoro nam slijedi vrijeme usporene monetarne ekspanzije, a onda i pitanje što će biti s kamatnim stopama²¹.

Padanje stope inflacije može se povezati i sa snažnom konkurencijom kojom se omogućuje ponuda sve jeftinijih dobara, ali i s vjerodostojnosti središnjih banaka (HUB_Analize_br. 73, 2021.). Uz središnje banke, važna je i uloga poslovnih banaka jer šira dostupnost kredita potiče agregatnu potražnju a time i inflaciju. Međutim, ovaj efekt je slabiji pri izostanku potražnje za kreditima. Ovakva situacija najčešće je prisutna u uvjetima visoke zaduženosti koja ograničava porast potražnje i pridonosi manjoj inflaciji. Dosadašnja predpandemijska istraživanja bila su pokazala ograničenost kapaciteta privatnog sektora u Hrvatskoj za daljnje zaduživanje i da rast gospodarstva između 2014. i 2017. godine nije popraćen snažnijim porastom kredita²². Ipak, od 2017. godine postupno oživljava tržište kredita čemu su svakako pomogla subvencioniranja nekretnina²³. Do kraja 2019. rastu i gotovinski nenamjenski krediti, ali stagniraju 2020. i 2021. godine (slika 18.)²⁴. Kod poduzeća ukupan iznos kreditiranja relativno slabi od kraja 2011. do kraja 2019. godine, što

²⁰ Vidjeti priopćenja na internetskoj stranici ECB-a (ECB, 2021.). Prema najnovijim projekcijama ECB-a očekuje se da će inflacija 2021. godine iznositi 2,2%, ali da će tijekom iduće dvije godine nastupiti dezinflacija od 1,7% (2022.) i 1,5% (2023.). U ovom smo radu zanemarili Sjedinjene Države jer za Hrvatsku nisu važan vanjskotrgovinski partner. Međutim, preko eurozone zbivanja u SAD-u lako se mogu prevaliti i na hrvatsko gospodarstvo. Tamo kvartalna inflacija na godišnjoj razini ubrzava od studenoga 2020. godine, što je dovelo do straha financijskih tržišta da bi FED mogao pokrenuti restriktivnu monetarnu politiku. S obzirom na to da je inflacija – u odnosu na eurozonu – ovdje značajnije uzrokovana agregatnom potražnjom, takva restriktivna kretanja neće imati efekta samo na nižu inflaciju nego i na manju gospodarsku aktivnost. Manjim američkim uvozom to bi i svjetsko gospodarstvo moglo dovesti u negativnu spiralu.

²¹ U SAD-u izmijenjena su očekivanja prema ranijem porastu kamatnih stopa već tijekom iduće godine. ECB-ov Pandemijski program hitne kupnje (PEPP) traje do ožujka 2022. godine uz mogućnost produžetka, a neka značajna gospodarstva poput njemačkog i talijanskog iduće godine premašuju razinu iz 2019. godine pa se očekuje da će program sužavanja ekspanzije (engl. *tapering*) kasniti za američkim barem godinu-dvije (Gatara, 2021; Šonje, 2021).

²² Vidjeti npr. Stipković & Bogdan (2017).

²³ Prema Kunovac & Žilić (2021) subvencioniranje nekretnina između 2015. i 2019. godine povećalo je cijene stanova.

²⁴ Korisno je također istaknuti i kredite kućanstvima po kreditnim karticama i prekoračenja po tekućim računima i ako im je ukupan udio u srpnju 2021. godine oko 7%. U ukupnoj masi kredita kućanstvima značaj im se smanjuje premda je između 2010. i 2016. godine na njih otpadalo 9 – 10%. Tijekom pandemije vrijednost "minusa" na tekućim računima raste sa 6,5 (travanj 2020.) na 6,8 milijardi kuna (studen 2020.). Do travnja 2021. godine slijedi im pad na oko 6,3 milijarde i blagi rast na oko 6,4 milijarde u srpnju 2021. Krediti po kreditnim karticama imaju tendenciju pada, ali im je vrijednost u koronakrizi između travnja i studenoga 2020. godine bila stabilizirana.

svjedoči o relativno slaboj domaćoj potražnji čak i prije pandemije krize, ali upućuje i na značaj manje potražnje na ekonomsku aktivnost Hrvatske u pandemijsko vrijeme.

Na nisku inflaciju mogu se odraziti i demografske promjene. Starenje stanovništva zabilježeno je na razini cijele Europske unije, ali sve zemlje nisu podjednako pogođene. Akrap (2014) ističe da su u najlošijem stanju upravo one zemlje u kojima tržište rada nije prilagođeno potrebama obitelji s malom djecom, što je svojstveno zemljama kontinentalne Europe. Slučaj Njemačke pokazuje da ni potražnja za radom nužno ne povlači demografski oporavak, ali zemlje slabije razvijenog tržišta rada imaju lošu demografsku sliku. A osim nepovoljnim uvjetima za ekonomsku aktivnost demografsko starenje se odražava i u niskoj inflaciji (zbog slabije potražnje)²⁵, što su pokazali Juselius & Takáts (2018)²⁶ i Han (2019). Han (2019) izravno napominje da se utjecaj demografije događa direktno preko očekivanja i indirektno preko kamatnih stopa. Pritom napominje da utjecaj starenja na dezinflaciju nije primaran problem u kratkom roku, ali se dugoročno ne smije zanemariti²⁷. Yoon, Kim, & Lee (2018) upućuju na pozitivnu vezu između rasta populacije i stope inflacije koja se – kad se razmatra utjecaj starenja stanovništva na inflaciju – može interpretirati i u suprotnom smjeru (starenje i dezinflacija)²⁸. Kanal preko kojeg se to odvija odnosi se na manju agregatnu potražnju uz spor odgovor ponude. Carvalho, Ferrero, & Nechio (2016) išli su i dalje i istražili utjecaj demografije na realne kamatne stope, ali je teorijski efekt starenja ipak nepoznat. S jedne strane dulje trajanje života smanjuje realne kamatne stope zbog štednje za budućnost. Dulje trajanje života u konačnici za posljedicu ima i smanjenje broja stanovnika, ali ono može utjecati na manje realne kamatne stope jer opada granični proizvod kapitala (zbog rasta kapitalne opremljenosti rada), ali je moguć i porast realnih kamatnih stopa. Umirovljenici štede manje od radnika pa je, s

²⁵ Općepoznata je veća sklonost potrošnji starijeg stanovništva (Deaton, 2005) odnosno manja stopa štednje. Prema standardnim modelima rasta (npr. Solow, 1956) to makar u tranzitornom razdoblju smanjuje stopu rasta, ali i u ravnotežnom stanju smanjuje ukupan BDP po stanovniku i stopu rasta ukupnog BDP-a.

²⁶ Međutim, za razvijene zemlje Juselius & Takáts (2016) pokazuju da porast koeficijenta dobne ovisnosti potiče inflaciju, dok je veći udio radnog kontingenta povezan s manjom inflacijom.

²⁷ Hanovo istraživanje usmjereno je na Hong Kong, Singapur i središnju Kinu i pokazuje da porast udjela mladih djeluje inflatorno, a udjela starih na smanjivanje inflacije. Zaključuje da je utjecaj demografije važniji u Hong Kongu i središnjoj Kini.

²⁸ Osim utjecaja na inflaciju kod ovih se autora razmatraju i efekti na druge varijable poput ekonomskog rasta, štednje i investicija te fiskalnog salda. Utjecaj na realne ekonomske varijable je negativan, dok su rezultati kod proračunskog salda mješoviti.

pogoršanjem dobne strukture, i manja štednja, a s njom i realne kamatne stope rastu. Ukupan empirijski efekt na kamatne stope je ipak negativan. Bobeica, Lis, Nickel, & Sun (2017) također pokazuju da je veza između inflacije i stope rasta radnog kontingenta pozitivna, odnosno da starenje stanovništva može djelovati dezinflacijski.

Iduća stvar koju ekonomisti razmatraju je poveznica između inflacije i nejednakosti. Albanesi (2007) pokazuje da je veći stupanj nejednakosti povezan sa većom inflacijom. Pojedini istraživači u svojim radovima uzimaju inflaciju kao regresorsku, a indikatora nejednakosti kao zavisnu varijablu, ali zbog niske razine nejednakosti u članicama EU navođenje tih radova nije od velike važnosti za ovaj rad²⁹.

4. ZAKLJUČAK

U radu se analizira stopa inflacije za Hrvatsku i eurozonu, pri čemu se razina cijena prati BDP deflatorom, CPI-em i PPI-em u industriji. Najveći dio kod BDP deflatora otpada na komponentu osobne potrošnje, što je i razumljivo zbog njezina dominantnog udjela u BDP-u, dok je uvoz negativna komponenta deflatora. Zaključivanje je nešto složenije pri dekomponiranju postotne promjene deflatora. Tada u kriznim uvjetima uvoz može biti i čimbenik koji pozitivno utječe na inflaciju (2009. i 2020.). Značaj drugih komponenti BDP-a uglavnom je bio pozitivan. Neovisno o indikatoru razine cijena nakon 2008. godine, inflacija je znatno niža nego prije krize.

Značajan dio rada posvećen je potrošačkim cijenama (CPI) koji se prati od 2004. premda su s njim usporedivi DZS-ov indeks troškova života između 1998. i 2003. godine. Između 2004. i 2014. godine sa svojim značenjem osobito se izdvajaju cijene hrane (osobito kod najveće potrošačke inflacije 2008.). Cijene hrane uglavnom su bile pozitivan čimbenik inflacije s iznimkom 2009. i 2014. i većeg dijela 2021. godine. Od 2015. osobito su značajne cijene goriva kako u utjecaju na smanjenje inflacije 2015. i 2016. te većem dijelu 2020., tako i u razdobljima rastuće inflacije 2017. – 2018.,

²⁹ Neki od tih radova su: Correia (2009), Balcilar, Chang, Gupta, & Miller (2018) i Monin (2014). Zaključci Correia (2009) i Monin (2014) suprotstavljeni su jer u prvom radu manja inflacija potiče jednakost, a u drugom je veza nejednakosti i inflacije U oblika (manja inflacija – veća nejednakost). Balcilar, Chang, Gupta, & Miller (2018) potvrđuju pozitivan utjecaj inflacije na nejednakost kada inflacija prijeđe određenu vrijednost, dok je ispod te vrijednosti veza negativna čime su ti zaključci slični onima koje ima Correia (2009).

ali i 2021. godine. No u domaćoj javnosti znatno veću zabrinutost stvara rastući doprinos cijena hrane u ukupnoj inflaciji nakon svibnja 2021. godine. Premda su većim dijelom prvog polugodišta 2021. godine na cijene hrane dominantno utjecale cijene mesa, snažniji doprinos cijena hrane u srpnju, kolovozu i rujnu vezan je uz cijene ulja i masti, povrća te mlijeka sira i jaja. Dekomponirana je inflacija iz HICP-a za zemlje eurozone te je potvrđeno da su prehrana te goriva i maziva bila važna odrednica inflacije. Rad također istražuje i postotnu promjenu PPI indeksa, ali se pokazalo da su na nju u najvećoj mjeri utjecale cijene energije.

Svi opisani elementi idu u prilog tome da je inflacija u Hrvatskoj pod dominantnim utjecajem troškovne komponente. Iako je zbog obujma članka izostavljena iz finalnog teksta, načinjena je i pojednostavnjena regresijska analiza koja je potvrdila značaj uvoznog deflatora na domaću inflaciju. U pozadini ovih rezultata vjerojatno je zajednički element – cijene fosilnih goriva koje su u znatnoj mjeri uvozna komponenta utječu (s drugim uvoznim dobrima) i na uvozni deflator, i na PPI (za energiju ili ukupni), što se u konačnici odražava i na cijene dobara i usluga koje koristi krajnji potrošač. No posrednim putem (npr. dinamikom i strukturom kredita kućanstvima i poduzećima) može se također ustanoviti da se ne može unaprijed isključiti i uloga potražnje u slabijoj inflaciji nakon 2009. godine. Ali ukupne je zaključke poželjno donijeti na temelju dulje vremenske serije (kvartalne ili mjesečne), što će biti cilj budućih istraživanja uz primjenu drukčijih statističkih i ekonometrijskih tehnika.

LITERATURA


- Akrap, A. (2014). Činitelji fertiliteta u Hrvatskoj: nekad i danas. U A. Akrap, I. Čipin, & M. Strmota, *Demografija u Hrvatskoj* (str. 33-64). Zagreb: Ekonomski fakultet – Zagreb.
- Albanesi, S. (2007). Inflation and Inequality. *Journal of Monetary Economics*, 54(4), str. 1088-1114.
- Balcilar, M., Chang, S., Gupta, R., & Miller, S. M. (2018). The Relationship Between the Inflation Rate and Inequality Across U. S. States: A Semiparametric Approach. *Quality and Quantity*, 52, str. 2413-2425.
- Bobeica, E., Lis, E., Nickel, C., & Sun, Y. (January 2017). Demographics and inflation. *ECB Working Paper Series*.
- Carvalho, C., Ferrero, A., & Nechio, F. (2016). Demographics and Real Interest Rates: Inspecting the Mechanism. *Federal Reserve Bank of San Francisco WPS 2016-05*.
- Correia, I. H. (2009). Inflation and Inequality. *Economic Bulletin Banco de Portugal*, str. 161-171.
- Deaton, A. (2005). Franco Modigliani and the Life Cycle Theory of Consumption. *Banca Nazionale del Lavoro Quarterly Review*, 58(233-234), str. 91-107.
- ECB. (9. 9. 2021.). *Press Conference 9 September 2021*. Preuzeto 15. 9. 2021. iz https://www.ecb.europa.eu/press/pressconf/html/press_conference.en.html.
- Ehrhardt, M. (1. 10. 2021.). Skuplji automobili i rast inflacije zbog korone. *Deutsche Welle*. Preuzeto 2. 10. 2021. iz <https://www.dw.com/hr/skuplji-automobili-i-rast-inflacije-zbog-korone/a-59374595>
- Europska_komisija. (Summer 2021). *European Economic Forecast*. Europska komisija.
- Eurostat. (1. 10. 2021.). *Euroindicators*. Dohvaćeno iz <https://ec.europa.eu/eurostat/documents/2995521/11563291/2-01102021-AP-EN.pdf/18dab5f9-9b23-7635-cc31-9112465da2fb>
- Gatara, M. (7. 10. 2021.). *Počelo je, počelo*. Preuzeto 10. 10. 2021. iz Ekonomski lab: <https://arhivanalitika.hr/blog/pocelo-je-pocelo/>
- Han, G. (2019). Demographic Changes and Inflation Dynamics. *HKIMR Working Paper No. 02*.

- HNB. (2021). *Makroekonomska kretanja i prognoze* (Svez. 6).
- HUB_Analize_br. 73 (2021). *Inflacija, kamatne stope i krediti u post-covid razdoblju*. Zagreb: Arhivanalitika i Hrvatska udruga banaka.
- Juselius, M., & Takáts, E. (2016). Can Demography Affect Inflation and Monetary Policy? *BIS Working Papers No 485*.
- Juselius, M., & Takáts, E. (2018). The Enduring Link Between Demography and Inflation. *BIS Working Papers No 722*.
- Kunovac, D., & Žilić, I. (srpanj 2021.). Dome slatki dome: Utjecaj subvencioniranja stambenih kredita na tržište nekretnina u Hrvatskoj. *Istraživanja I-63*.
- Lovrinčević, Ž. (2009). Tehnološka složenost i struktura ponude i potražnje industrijskih proizvoda u Hrvatskoj. *Ekonomski pregled*, 60(11), str. 535-569.
- McCully, C. P., Moyer, B. C., & Stewart, K. J. (2007). A Reconciliation Between the Consumer Price Index and the Personal Consumption Expenditures Price Index. *BEA Papers 0079*.
- Monin, P. (2014). Inflation and Income Inequality in Developed Economies. *CEP Working Paper 2014/1*.
- Solow, R. M. (1956). A Contribution to the Theory of Economic Growth. *Quarterly Journal of Economics*, 70, str. 65-94.
- Stipković, P., & Bogdan, Ž. (2017). Pokazatelji hrvatskog bankovnog sustava i gospodarski rast. *Zbornik Ekonomskog fakulteta u Zagrebu*, 15(2), str. 179-204. doi:<https://doi.org/10.22598/zefzg.2017.2.179>
- Šonje, V. (23. 9. 2021.). *FED: No Surprises*. Preuzeto 5. 10. 2021. iz Ekonomski lab: <https://arhivanalitika.hr/blog/fed-no-surprises/>
- Tkalec, M., Vizek, M., & Verbič, M. (2014). Balance Sheet Effects and Original Sinners' Risk Premiums. *Economic systems*, 38(4), str. 597-613. doi:10.1016/j.ecosys.2014.05.005.
- U. S. Bureau of Labor Statistics. (May 2011). Consumer Price Index: First Quarter 2011. *Focus on Prices and Spending*, 2(3).
- Yoon, J.-W., Kim, J., & Lee, J. (2018). Impact of Demographic Changes on Inflation and the Macroeconomy. *KDI Journal of Economic Policy*, 40(1), str. 1-30. doi:<http://dx.doi.org/10.23895/kdijep.2018.40.1.1>


DODACI

Slika 19. Komponente deflatora BDP-a


OSOBNJA POTROŠNJA




INVESTICIJE




DRŽAVNA POTROŠNJA




PROMJENA ZALIHA




IZVOZ ROBA



IZVOZ USLUGA




UKUPAN UVOZ




Izvor: prikaz autora.

Slika 20. Doprinosi inflaciji mjerenoj potrošačkim cijenama (2004. – 2020.)




Izvor: izračun autora na temelju podataka iz DZS-a.

Slika 21. Doprinosi inflaciji mjerenoj potrošačkim cijenama po mjesecima (2020. – 2021.) u Hrvatskoj



Izvor: izračun autora na temelju podataka iz DZS-a.

Slika 22. Doprinosi inflaciji mjerenoj potrošačkim cijenama po mjesecima u eurozoni (2012. – 2021.)



Napomena: Na razini eurozone razina cijena se ne mjeri CPI-em, nego harmoniziranim indeksom potrošačkih cijena (engl. HICP) koji nije konstruiran da prati indeks troškova života.

Izvor: Eurostat.

COMPARATIVE ANALYSIS OF POST-COVID INFLATION FOR CROATIA AND THE EUROZONE – CAN IT BE ASSESSED AS PROBLEMATIC?

Abstract

Since the recent economic crisis, both Croatia and the Eurozone have experienced very low and sometimes negative inflation in conditions when money market interest rates were very close to zero. In economic theory this is known as a situation that greatly slows recovery because it prevents a fall in the real interest rate. The initial phase of the recent crisis (2008-2010) in Croatia was characterized by a sharp decline in inflation, which was both negative between July 2015 and November 2016, and then positive until the beginning of the COVID crisis. In the 2020 pandemic, the price level was declining, but the positive dynamics of inflation in 2021 has raised concerns. Data for August 2021 show inflation of 3.1%, to which energy and food prices contribute the most. The conclusions of the paper show that inflation in Croatia is predominantly the result of higher costs, but the effect of demand, especially in the last ten years, cannot be completely ruled out.

In addition to foreign trade, it is important to emphasize the role of banks in the Eurozone, which dominate the ownership of assets of the Croatian banking sector. Through them, the activities of the European Central Bank (ECB) to stimulate inflation, at least indirectly, spill over into economic developments in Croatia. The ECB's measures have also helped Croatia to continue with lower interest expenses in the current crisis. The announcements from the ECB suggest that with the growth of inflation monetary expansion will decrease, but we do not expect interest rates to rise before 2023-2024.

Keywords: GDP deflator, Consumer Price Index, Producer Price Index in Industry, competitiveness.

JEL klasifikacija: R110
Izvorni znanstveni rad

GOSPODARSKA REVITALIZACIJA NERAZVIJENOG PODRUČJA POGOĐENOG POTRESOM (SLUČAJ SISAČKO-MOSLAVAČKE ŽUPANIJE)

Vladimir Čavrak*

SAŽETAK

Razoran potres koji se dogodio 28. i 29. prosinca 2020. godine nanio je ogromne izravne i neizravne štete na području Sisačko-moslavačke županije, koje je po stupnju razvijenosti rangirano kao izrazito nerazvijeno. Zbog toga je obnova i gospodarska revitalizacija ovog područja suočena s brojnim nepoznicama i izazovima. Niska razina gospodarske i društvene razvijenosti u kombinaciji s demografskom erozijom upućuje na slabe mogućnosti generiranja autonomnog razvoja te potrebu poduzimanja snažnih egzogenih poticaja. S obzirom na brojne specifičnosti povijesnog razvoja te zatečenog stanja na promatranom području, potrebno je analizirati teorijska i empirijska iskustva razvoja sličnih područja u drugim zemljama radi formuliranja mogućeg modela lokalnog ekonomskog razvoja i modela regionalne politike. Osnovna hipoteza jest da promatranu regiju karakteriziraju velike specifičnosti, duboka nerazvijenost i regija u nestajanju te izvrnutost seriji egzogenih šokova (ratna razaranja, tranzicija, pandemija COVID-19 i nekoliko razornih potresa), zbog čega je potrebno koristiti specifičan teorijski i praktičan pristup formuliranju strategije i

* Prof. dr. sc. Vladimir Čavrak, Ekonomski fakultet Sveučilišta u Zagrebu (e-mail: vcavrak@net.efzg.hr).

različitih programa obnove i gospodarske revitalizacije. U radu se predlaže strategija cjelovitog teritorijalnog razvoja s osloncem na sve vidove raspoloživog teritorijalnog kapitala kombiniranog s egzogenom i endogenom strategijom lokalnog ekonomskog razvoja.

Ključne riječi: lokalni ekonomski razvoj, regionalni razvoj, potpomognuta područja, potres.

1. UVOD

Potpomognuta područja Republike Hrvatske pogođena potresom¹ moguće je definirati s obzirom na dva kriterija: (1) klasifikacija jedinica lokalne samouprave prema važećem Indeksu razvijenosti i (2) stupanj oštećenja objekata mjeren omjerom broja objekata koji su pregledom statičara dobili crvene i žute naljepnice u odnosu na ukupan broj stambenih jedinica (DZS, Popis stanovništva 2011.). Kako je potres pogodio nekoliko susjednih županija,² u ovom radu će se analiza temeljiti na činjenici da je epicentralno područje potresa bilo na području Sisačko-moslavačke županije te da su u toj Županiji evidentirane najveće štete.³ Prema navedenim kriterijima područje Sisačko-moslavačke županije pogođeno potresom obuhvaća četiri grada i deset općina,⁴ odnosno cjelokupno jugozapadno područje županije (Sisak i Banovina).

¹ Sisačko-moslavačku županiju i šire područje oko nje, 28. i 29. prosinca 2020. godine, pogodila je serija razornih potresa, od kojih je najjači bio 29. prosinca 2020. godine u 12:19 sati, magnitude 6,2 prema Richteru s epicentrom 5 km jugozapadno od Petrinje na dubini od 11,5 km. Intenzitet potresa u epicentru je bio VIII-IX stupnjeva EMS ljestvice. Nakon glavnog potresa uslijedio je velik broj naknadnih potresa. Na petrinjskom području, samo u razdoblju od 28. prosinca 2020. do 28. siječnja 2021. godine dogodila su se 622 potresa magnitude veće ili jednake 2.0. Do kraja kolovoza 2021. godine na širem području oko epicentra zabilježeno je preko 1.200 potresa različitog intenziteta.

² Vlada Republike Hrvatske je na 35. sjednici održanoj 4. siječnja 2021. godine donijela Odluku o proglašenju katastrofe na području pogođenom potresom, i to za područje Sisačko-moslavačke, Zagrebačke i Karlovačke županije.

³ Ukupna izravna šteta prouzročena potresom procijenjena je na temelju pravila Europske unije i metodologije Svjetske banke. Iznos štete od 41,6 milijardi kuna, odnosno 5,5 milijardi eura predstavlja 10,2 posto bruto nacionalnog dohotka Hrvatske. Međutim, ako stavimo u omjer izravne štete od potresa na području Sisačko-moslavačke županije koje iznose 37,5 milijardi kuna prema bruto domaćem proizvodu Županije, šteta iznosi više od 300 posto BDP-a Županije.

⁴ Gradovi: Sisak, Petrinja, Glina i Hrvatska Kostajnica. Općine: Lekenik, Sunja, Donji Kukuruzari, Majur, Dvor, Topusko, Gvozd, Jasenovac, Hrvatska Dubica i Martinska Ves. Do 17. rujna 2021. godine prijavljene su štete na 41.511 objekata. Potpuno je neupotrebljivo 4.814 stambenih objekata, a privremeno je neupotrebljivo 8.566 objekata (<https://potresinfo.gov.hr/pregled-aktivnosti-17-rujna-2021/665>). Budući da još uvijek postoje nepregledani objekti, može se aproksimirati da preko

Kako je većina statističkih podataka nedostupna za razinu općina i gradova, u ovom će se radu veći dio analize zasnivati na podacima za cijelu Sisačko-moslavačku županiju, što opravdavamo time da je potres pogodio izravno, ali i neizravno cijeli prostor Županije pa i šire te da su glavni nalazi za potpomognuta područja svakako lošiji od podataka dobivenih analizom cijelog područja Županije.⁵ Budući da je primarni cilj i svrha ovog rada definirati okvirni razvojni model, prethodno ograničenje nije od većeg značenja.

S obzirom na cilj i svrhu, rad obuhvaća nekoliko cjelina. U prvoj cjelini se proučavaju teorijske osnove ekonomske regeneracije područja pogođenih prirodnim katastrofama, posebno potresima te moguće strategije ekonomskog razvoja zaostalih područja s divergentnom stopom rasta. U drugoj cjelini analiziraju se gospodarski trendovi i zatečeno stanje na području Sisačko-moslavačke županije, a u zadnjoj cjelini izvodi se mogući model gospodarske regeneracije područja pogođenog potresom koje je ujedno i izrazito nerazvijeno pa je suočeno s višestrukim razvojnim ograničenjima.

2. TEORIJSKI REZULTATI DOSADAŠNJIH ISTRAŽIVANJA

2.1. Teorijske osnove gospodarske revitalizacije potresom pogođenih područja

Izučavanje ekonomske teorije i svjetskih iskustava u revitalizaciji potresom pogođenih područja za Republiku Hrvatsku ima osobito veliko značenje jer je u kratkom vremenu bila izložena brojnim potresima s osobito velikim štetama i dvama potresima s razornim posljedicama na području Zagreba (22. ožujka 2020.) i Banovine (tzv. "petrinjski potres" 28. i 29. prosinca 2020. godine).

Da bi se moglo pristupiti sustavnom sagledavanju i rješavanju brojnih problema koji su posljedica ovih prirodnih katastrofa, nužno je imati čvršće

50.000 osoba ili više od jedne trećine stanovništva na ovom području nije u mogućnosti stanovati u svom objektu ili ima rizik stanovanja u nesigurnom objektu.

⁵ Na 37. sjednici Vlade Republike Hrvatske, održanoj 14. siječnja 2021. godine, donesene su dvije odluke o načinu rješavanja posljedica potresa. Tim su odlukama razdvojeni procesi obnove zgrada oštećenih potresom od procesa društvene i gospodarske revitalizacije potpomognutih područja. Obje su se odluke primarno odnosile na čitavo područje Sisačko-moslavačke županije, što također opravdava analitički pristup u ovom radu.

uporišne točke u dobrim procjenama vrste i iznosa izravnih i neizravnih te induciranih šteta. Ovaj rad se uglavnom bavi ekonomskim štetama, ali razumije se da potres uvijek izaziva i štete u brojnim drugim aspektima ljudskog života koje nije moguće monetizirati i obuhvatiti standardnim ekonomskim analitičkim alatima. Ekonomske procjene šteta obično uključuju (a) izravne štete na objektima (i ljudima), (b) neizravne štete i (c) multiplikativne (inducirane) učinke tih šteta koje djeluju u duljem razdoblju iza potresa (ponekad i desetljeća). Sam proces procjene ovih šteta je veoma zahtjevan i kompliciran te zahtijeva multidisciplinarni timski rad pa ga nije moguće obaviti u kratkom roku.⁶

Postoji opsežna literatura o ekonomici potresa čiji nalazi upućuju na potrebu precizne identifikacije vrsta nanesene štete. Naime, nalazi istraživanja razlikuju se s obzirom na to je li dominantna šteta nastala na produktivnom proizvodnom kapitalu, na trajnim potrošnim dobrima (automobili, namještaj i sl.) ili na rezidencijalnim objektima. To je važno radi procjene multiplikatora fiskalnih i monetarnih programa. Multiplikator ulaganja u novi proizvodni kapital može biti veći i trajniji od multiplikatora fiskalnih transfera za nabavu trajnih potrošnih dobara ili gradnju rezidencijalnih objekata.

U svakom slučaju, da bi se moglo pristupiti cjelovitoj obnovi i regeneraciji potresom pogođenog područja, prvi važan korak je izrada detaljne i pouzdane procjene štete. Do sada su ove procjene napravljene za potrebe izrade zahtjeva za dodjelu sredstava iz Fonda solidarnosti Europske unije (EUSF). Budući da se ove procjene izrađuju po metodologiji predviđenoj za podnošenje brzog zahtjeva za pomoć koji se mora podnijeti najkasnije u roku od dvanaest tjedana od nastanka prve štete, sasvim je jasno da se tu ne radi o cjelovitoj procjeni štete. Ova procjena je obuhvatila samo sektore stanovanja, obrazovanja, zdravstva, kulture, gospodarstva, makroekonomije i troškove smanjenja rizika od katastrofa.

Sve navedeno uglavnom se odnosi na izravne štete, dok će proces utvrđivanja neizravnih i multiplikativnih šteta biti obavljen u daljoj budućnosti. Cjelokupan posao procjene ovih šteta dodatno je zakompliciran činjenicom da su se potresi dogodili usred epidemije koronavirusa pa će neizravne i multiplikativne štete biti teško pridružiti jednom ili drugom

⁶ Ovaj dio rada oslanja se na dijelove članka *Makroekonomski aspekti obnove, izravna i neizravna šteta*, objavljenog u časopisu, *Perspektive*, Zagrebačka inicijativa, broj 1-2, 2020. godine, str. 23.-27., autor Čavrak, V.

moгуćem uzroku. Ovdje izostavljam još jednu kompleksnu problematiku, a koja se tiče temeljnih polazišta za procjenu izravnih šteta koja zasad nije definirana, a odnosi se na kriterije i polazišne točke tih procjena. Zasad je nejasno i nedefinirano pitanje hoće li se štete procjenjivati u odnosu na troškove dovođenja u prethodno stanje različitih objekata, hoće li se neki i koji objekti rušiti uz gradnju novih ili će se neki objekti graditi iznova, ali na drugim lokacijama itd. U svakom slučaju, nepostojanje detaljne procjene šteta predstavlja ozbiljan hendikep za mogućnost dizajniranja programa i projekata uklanjanja gospodarskih šteta kao i za dobru i preciznu procjenu učinaka ekonomskih programa usmjerenih na eliminiranje posljedica potresa.

Postoji opsežna znanstvena literatura o ekonomskim posljedicama prirodnih katastrofa, posebno potresa. Može se konstatirati da su brojni autori proveli vrlo zanimljiva i sveobuhvatna istraživanja posljedica takvih događaja. U ekonomskoj znanosti postoji opća suglasnost da prirodne katastrofe imaju neposredne i razorne posljedice u kratkom roku. Kod dugoročnih učinaka nalazi istraživanja su različiti i zavise od slučaja do slučaja. Prema jednom sveobuhvatnom istraživanju koje je koristilo empirijske podatke o potresima u svijetu od 1973. do 2015. godine, negativni dugoročni utjecaji na rast prosječne zemlje mogu se usporediti s nalazima za prirodne katastrofe povezane s klimom. Tipičan potres smanjuje bruto domaći proizvod po stanovniku za 1,6% godišnje u razdoblju od osam godina iza događanja potresa. Također, zemlje s niskim i srednjim dohotkom doživljavaju veće ekonomske štete od zemalja s visokim dohotkom koje čak imaju i pojedinačna iskustva ubrzanja rasta kao učinak brze obnove i izgradnje novih objekata i struktura. Iz navedenog se može zaključiti da pravilna i primjerena reakcija fiskalne i monetarne politike koje podržavaju dobar program brze obnove mogu relativno brzo povećati stope rasta i nadoknaditi štete nastale zbog potresa.

Istraživanje koje je obuhvatilo 95 talijanskih provincija koje su u razdoblju 1986. – 2011. godine imale 22 seizmička razdoblja nije pokazalo značajan negativan učinak na output (u nekim slučajevima je učinak bio pozitivan). Slične rezultate nalazimo i u istraživanju dvaju velikih potresa na Novom Zelandu (2010. i 2011.). Navedeno istraživanje je utvrdilo veoma mali učinak potresa na agregatni output (BDP) i umjereno smanjenje stope inflacije. Pritom se konstatira da su mjere državne fiskalne politike i monetarne mjere centralne banke uspjele ublažiti utjecaj šteta na makroekonomske učinke. Za naše razmatranje važan je nalaz ovog

istraživanja koje je utvrdilo da su **puno veći učinci potresa na regionalnoj nego na nacionalnoj razini**. U pogledu zagrebačkog i petrinjskog potresa valja zapaziti da centralna i lokalna država još uvijek nemaju obrise cjelovitog programa eliminacije svih šteta, dok je identifikacija šteta prilično zamagljena istodobnom pojavom *lockdowna* uslijed epidemije koronavirusa.⁷

2.2. Teorijski pristup izboru strategije gospodarske revitalizacije izrazito nerazvijenih područja

Kako se u ovoj studiji slučaja radi o području koje je istodobno suočeno s višestrukim razvojnim ograničenjima i preprekama, nužno je analizirati iskustva i teorijska dostignuća relevantna za regeneraciju takvih područja. Sisačko-moslavačka županija je uz ogromne štete od potresa dugoročno bila izvrnuta izrazito negativnim trendovima gospodarskog i demografskog razvoja. Povijesni aspekt razvoja područja nas nužno vraća na problem nezavršene i loše provedene tranzicije iz jedne od najrazvijenijih industrijskih struktura potkraj prošlog stoljeća u područje koje se danas nalazu na oko 42% bruto domaćeg proizvoda po stanovniku u odnosu na prosjek Europske unije i jedno je od najnerazvijenijih u Republici Hrvatskoj.⁸ Radi se o području koje je paralelno s tranzicijskim gubicima doživjela iznimno velike materijalne i ljudske gubitke u vrijeme Domovinskog rata 1991. – 1995. koji u kasnijim desetljećima nisu kompenzirani. Zbirno možemo konstatirati da se radi o području koje je već više od tri desetljeća izvrnuto negativnim gospodarskim trendovima. Budući da se radi o vremenskom rasponu jedne aktivne generacije u kojem nije ostvaren rast i konvergencija s prosjekom Republike Hrvatske, to je

⁷ Početkom rujna 2021. godine, 18 mjeseci nakon zagrebačkog i devet mjeseci nakon petrinjskog potresa, Vlada RH odlučila se na promjene postojećeg nefunkcionalnog Zakona o obnovi zgrada oštećenih potresom... (NN 102/20 i 10/21) koji je bio na snazi od 6. veljače 2021. godine, ali bez značajnijih učinaka na obnovu.

⁸ Dugoročno nepovoljne razvojne trendove Sisačko-moslavačke županije, unatoč značajnim metodološkim razlikama i prostornom obuhvatu, dobro ilustrira rang razvijenosti Županije u odnosu na prosjek Republike Hrvatske. Tako je na primjer, nekadašnja Zajednica općina (ZO) Sisak, od deset tadašnjih zajednica općina zauzimala visoko četvrto mjesto, odmah iza Grada Zagreba, ZO Rijeka i ZO Split s indeksom razvijenosti 92,24 u odnosu na prosjek Republike Hrvatske (1988), (Nujić, 1990). Ako razvijenost današnje Sisačko-moslavačke županije mjerimo bruto domaćim proizvodom po stanovniku, onda se ona nalazi među zadnje četiri županije od ukupno 20 plus Grad Zagreb s indeksom 64 u odnosu na prosjek suvremene Republike Hrvatske (2018). Dakle, radi se o tridesetogodišnjem zaostajanju za prosjekom Republike Hrvatske.

nužno proizvelo problem gubitka perspektive i povjerenja u životne šanse. Zbog toga je u zadnjim desetljećima došlo do masovnog iseljavanja mlade i obrazovane radne snage i do pada broja stanovnika. Time je značajno smanjena veličina i kvaliteta glavnog razvojnog resursa, a to je ljudski kapital. Zbog smanjenja ukupnog broja stanovnika te stalnog smanjenja poslovne aktivnosti smanjen je opseg lokalnog tržišta, što povratno djeluje na smanjenje potražnje za lokalnim proizvodima i uslugama. A kako je gotovo 90 posto lokalnoga gospodarstva usmjereno na lokalno tržište, dalje se smanjuje poslovna aktivnost i pogoršavaju financijski rezultati poslovanja. Zbog svega navedenog prostor Sisačko-moslavačke županije ušao je u "začarani krug siromaštva" i negativnu spiralu gospodarske i društvene razvijenosti.

Prethodno navedeno važno je razumjeti jer se radi o zatečenim pretpostavkama gospodarskog razvitka bez čijeg razumijevanja nije moguće pristupiti traženju adekvatne i učinkovite strategije izlaska iz tako kritičnog stanja. Pitanje izbora dobre strategije u čvrstoj je korelaciji sa zatečenim stanjem i uzrocima tog stanja. Ako se tome ne pristupi na dobar način, moguće je ponavljati dosadašnje pogreške i što je najgore, moguće je utrošiti velika sredstva, ali bez rezultata. To je razlog što se u nastavku dodatno propituju iskustva i zaključci na koje nas upućuju istraživanja o ključnim pitanjima generiranja rasta i razvoja područja sa sličnim razvojnim teškoćama.

Zašto neka mjesta i regije ostvaruju brzi gospodarski rast, a neka ne, to je pitanje koje već desetljećima zaokuplja mnoge znanstvenike, ekonomiste koji se bave regionalnim i lokalnim razvojem, ali i druge, ekonomiste koji se bave pitanjima rasta, geografe, prostorne planere, ali i kreatore ekonomskih politika. Razumijevanje pokretača rasta bio je intelektualni izazov koji je sredinom proteklog stoljeća pridonio utemeljenju posebne znanstvene discipline regionalne znanosti, a 90-ih godina prošlog stoljeća utemeljenju znanstvene discipline lokalnog ekonomskog razvoja. Pitanje pokretača rasta još uvijek je neka vrsta ekonomskog "*svetog grala*" koje s vremenom postaje još zahtjevnije s obzirom na brzu transformaciju globalne ekonomije koja utječe na sve regije, gradove i lokalne zajednice u regiji.

Procesi rasta značajno se razlikuju ovisno o lokaciji, kako zbog prirodnih osobina lokacije i različitog pristupa prirodnim resursima tako i zbog kvalitete koju stvara čovjek, a što uključuje pristup lokalnom i globalnom tržištu, veličinu stanovništva regije, što determinira opseg lokalnog tržišta, a

što sve zajedno utječe na izgled za ostvarenje rasta. Zbog navedenog, često se i naoko slična mjesta međusobno po mnogočemu razlikuju, a pogotovo su velike razlike između urbanih i ruralnih područja unutar regija i država. Postoje brojne studije koje su u pravilu fokusirane na određene tipove regija ili lokacija koje omogućuju detaljniji uvid u pokretače rasta i koje nam nude lekcije za bolje razumijevanje o tome koji su čimbenici važni i kako se na njih može utjecati.

Rana objašnjenja regionalnog rasta bila su relativno jednostavna i ponudila su vrlo široka objašnjenja koja su međutim davala malo informacija i slabu pomoć planiranju gospodarskog razvoja.⁹ Neoklasična ekonomija temeljila se na ideji da je rast rezultat povećanja ulaganja u kapital, poput tvornica, strojeva ili infrastrukture i rezultat rasta radne snage ili kao posljedica rasta oba ova čimbenika. Kasnija istraživanja Solowa (1956) i drugih dovela su u pitanje ovaj model, uz napomenu da se samo 15 posto rasta u SAD-u početkom 20. stoljeća moglo objasniti povećanjem kapitala i rada (Stimson i sur., 2009). Tvrdili su da je tehnološka promjena faktor koji nedostaje u razumijevanju rasta i da se razvoj bolje razumije kao proizvod sljedećih čimbenika: kapitala, rada i tehnoloških promjena. Iako je ta modifikacija bila intuitivno privlačna, opterećena je znatnim poteškoćama. Tehnološku promjenu je teško mjeriti i teško je – ako ne i nemoguće – predvidjeti tehnološki napredak. Također je teško procijeniti koje će tehnološke promjene utjecati na ukupnu produktivnost. Empirija je pokazala da postoje znatne razlike u ekonomskom učinku regija s inače usporedivim tehnološkim osnovama.

Puno više objašnjenja ponudio je rad Mankiw, Romer, Weil (1992) koji je istraživao čimbenike rasta odnosno čimbenike koji utječu na razlike u životnom standardu u svijetu, ali u uzorcima različitih zemalja. U kontekstu ovog rada važno je zapaziti razlike utjecaja različitih čimbenika u zemljama koje nisu proizvođači i izvoznice nafte od zemalja koje su članice OECD-a. U prvoj skupini zemalja koje nisu članice OECD-a i ne izvoze naftu, rast populacije i udio investicija u BDP-u objašnjava čak 59% ($R^2 = 0,59$) devijacija u BDP-u po stanovniku. Kad se navedenim čimbenicima pridoda i ljudski kapital, postotak objašnjenja raste na 77-78 posto. U zemljama OECD-a porast fizičkog kapitala i populacije objašnjava svega 6 posto, a

⁹ Dobar pregled ranih teorija i recentnih teorijskih i praktičnih postignuća na području regionalnog i lokalnog ekonomskog razvoja prikazan je u Beer i Clower (2020) pa je taj rad poslužio kao inspiracija za ovo poglavlje.

nakon dodavanja ljudskog kapitala postotak objašnjenja povećava se na 24 posto. Zbog toga za analizu čimbenika regionalnog rasta i razvoja u zemljama OECD-a veću vrijednost imaju empirijska istraživanja o kojima će kasnije biti govora, ali koja istražuju regionalne razlike unutar tih zemalja.

Teorije izvozne baze koje se temelje na izvozu ističu izravna strana ulaganja i prodaju robe i usluga kupcima izvan regije kao važan poticaj za rast i kao pokretač specijalizacije unutar regija. Rostow (1960) naglašava ulogu vodećeg (baznog) sektora ili industrije u pokretanju rasta na regionalnoj razini. Kako izvozna trgovina raste, regija će razvijati konkurentске prednosti u odnosu na druge regije zbog povećanja ekonomije razmjera i opsega. Slično tumači i teorija ekonomske baze, posebno popularna u SAD-u, ali i šire. Polazi od ideje da će povećanje prihoda i radnih mjesta stvorenih u izvoznim sektorima i industrijama inducirati nova radna mjesta i novi dohodak u drugim lokalnim poduzećima i djelatnostima, što će rezultirati dodatnim rastom lokalnoga gospodarstva kao cjeline. U praktičnom aspektu ova se ideja ostvaruje na način da se lokalna zajednica fokusira na privlačenje i zadržavanje poduzeća koja su usmjerena prema izvoznim tržištima tako što će im pružiti infrastrukturu koja pomaže njihovu preseljenju ili proširenju djelatnosti i da osigura radnu snagu odgovarajuće kvalifikacije.

Nova teorija rasta analitički se pak razlikuje od konvencionalnih neo-klasičnih po tome što razdvaja endogene (unutarnje) i egzogene (vanjske) čimbenike i prepoznaje unutarnje čimbenike kao temeljne pokretače rasta (Stimson i sur., 2009). Nova teorija rasta definira razvoj kao kontinuirani proces vođen "endogenom sposobnošću regije da uči i inovira". (Stimson i sur., 2009:8). Jedan pristup endogenog modela rasta pretpostavlja da razvoj ovisi o količini ljudskog kapitala u regiji, što utječe na sposobnost regije da inovira i tako zatvori jaz s razvijenijim regijama (OECD, 2009). Drugi pristup vidi rast potaknut nagomilavanjem ljudskog kapitala tijekom vremena s razvojem vođenim stalnim stjecanjem intelektualnih i tehničkih kapaciteta.

Nova teorija rasta sugerira da, kako je razvoj ili odsutnost razvoja, rezultat procesa unutar regije, mjesta mogu razviti vlastite putanje (pozitivne, horizontalne ili negativne). Čimbenici koji utječu na interne promjene uključuju razinu obrazovanja, lokalni institucionalni kapacitet, snagu lokalnog poduzetništva i tako dalje.

Ekonomski modeli nove ekonomske geografije omogućili su nam razumijevanje zašto potrošači i tvrtke imaju tendenciju aglomeriranja (nagomilavanja) u gradovima i regijama te zašto se zadržavaju u tim lokalitetima. Bazirajući se na radu Myrdala (1957) o kumulativnoj uzročnosti, Krugman (1991) je pokazao da su procesi kružne uzročnosti stvorili različite regije jezgre i periferije, s tim da su se razlike između njih s vremenom povećavale. Ono što je za temu ovog rada važno i što jasno proizlazi iz ove teorije jest da postoje možda čak i neizbježni rizici za manje razvijena mjesta i regije da će se bez ciljanog djelovanja njihovi nedostaci vremenom povećavati. Slučaj Sisačko-moslavačke županije i analiza u prethodnom poglavlju empirijski to bjelodano dokazuju.

Ovi modeli regionalnog rasta pomogli su nam da shvatimo zašto mjesta rastu, ali su ipak ponudili suviše pojednostavnjene odgovore zbog čega je u praksi bilo teško postići rast. To je dobro primijetio Rodríguez-Pose (2013) ustvrdivši da su ovi modeli doveli do standardiziranog odgovora na poticanje rasta koji se sastojao od većih ulaganja u infrastrukturu, poboljšanja obrazovanja i osposobljavanja, kao i promicanja inovacija. Očekivalo se da će ove aktivnosti poboljšati blagostanje uspješnih i manje razvijenih regija. Modeli su također potaknuli razvoj odozgo prema dolje, što je u velikoj mjeri unificiralo pristupe od države do države i od regije do regije. Modeli su, međutim, bili neadekvatni u ključnim područjima, kako u pogledu savjeta za regionalnu politiku do rastuće kritike regionalne politike *per se* (Svjetska banka, 2009), pa do sve većeg priznanja istraživača da postojeći modeli jednostavno nisu objasnili uzroke rasta. Stoga su bili potrebni novi pristupi (Beer & Clower, 2020).

O problematičnom utjecaju ulaganja u infrastrukturu na rast korisno pregledno istraživanje napravio je Valila (2020). On posebno upozorava da su brojna empirijska istraživanja odnosa infrastrukture i rasta bila neuvjerljiva, što proizlazi iz činjenice da je infrastrukturu zapravo teško definirati i mjeriti te da praznine u teoriji pridonose formulaciji pogrešnih empirijskih modela.

Poseban problem je što različita objašnjenja nisu podjednako istinita za sva mjesta te što zaključke i savjete nositeljima regionalne politike i politike lokalnog ekonomskog razvoja koji proizlaze iz pojedinačnih analiza oblikuju potpuno različiti čimbenici, poput dubine i prostornog obuhvata korištenih podataka, početnih pretpostavki istraživača, dostupnosti ključnih informacija i robusnosti korištenih modela. Zbog toga se stručnjaci i

praktičari koji se bave ekonomskim razvojem suočavaju s prividom mnoštva recepata za politike bez jasnih uputa o tome koji je put najprimjereniji, koje strategije treba usvojiti, kako ih provoditi i kako mjeriti njihov utjecaj (Beer, 2009). U tim je pitanjima potrebna veća jasnoća.

Nedavni radovi OECD-a daju korisne smjernice o tome kako mjesta rastu i koje vrste strategija i mehanizama lokalne zajednice i vlade mogu koristiti kako bi osigurale bolju ekonomsku budućnost. Rad OECD-a važan je jer ima nekoliko važnih prednosti koje često nedostaju drugim radovima. Prvo, OECD je uspio uložiti znatno vrijeme i resurse za razumijevanje dinamike rasta regije, a njihove su analize i recepti politike s vremenom postajali sve sofisticiraniji. Drugo, OECD je uspio prikupiti podatke i iskoristiti iskustvo gotovo svih razvijenih gospodarstava. Njihovi se zaključci s određenim pouzdanjem mogu generalizirati na gradskim, regionalnim i državnim razinama. Treće, OECD je bio u mogućnosti izgraditi vlastite baze podataka za analizu, što omogućava izvođenje pouzdanijih i čvršćih zaključaka. Konačno, OECD nije vezan za određenu paradigmu razvoja i stoga je sposoban razmišljati izvan ustaljenih teorijskih okvira (Beer & Clower, 2020).

Analize pristupa zemalja OECD-a politici regionalnog razvoja u kontekstu ciljeva ovog rada su nam posebno zanimljive i stoga što se regija koju ovdje promatramo, Sisačko-moslavačka županija, ali i cijela Republika Hrvatska zapravo nalaze u fazi razvoja koju su zemlje OECD-a prolazile prije nekoliko desetljeća. Zbog toga je za ovu prigodu, prije elaboracije suvremenog iskustva OECD-a, zanimljivo sumirati njihove pristupe politikama regionalnog razvoja u vrijeme kada su se te zemlje nalazile na istom stupnju ekonomskog razvoja na kojem je danas Republika Hrvatska.

Rad D. Wadleya (1986) sumira primjere glavnih regionalnih poticaja u europskim zemljama. Nabrojimo samo neke: Njemačka (subvencije za investicije, lokalni krediti s manjom kamatom), Francuska (subvencije putem regionalne politike, subvencije za regionalnu zaposlenost, porezne olakšice za lokalno gospodarstvo), Danska (povoljni krediti za poduzeća, dodjela investicijskih sredstava, povoljni komunalni zajmovi), Belgija (subvencija kamata, dodjela kapitala uz administrativne diskrecije), Italija (fondovske dodjele sredstava, nacionalna fondovska shema, porezne olakšice, olakšice u području socijalne sigurnosti), Luksemburg (dodjela kapitala i subvencija kamata, porezne olakšice, krediti za opremu), Nizozemska (investicijske premije), Ujedinjeno Kraljevstvo (dodjela

sredstava za razvoj regija, selektivna financijska pomoć), Švedska (zajmovi za lokaciju, dodjela lokacije, dodjela sredstava za zapošljavanje).

Od brojnih mjera regionalne pomoći u tadašnjih 18 zemalja OECD-a većina je koristila sljedeće (OECD, 1979):

- Izravna dodjela investicijskih sredstava za opremu i zgrade (14 zemalja)
- Subvencioniranje kamate (14 zemalja)
- Davanje garancije (15 zemalja)
- Fiskalne olakšice za investicije (11 zemalja)
- Pomoć za mobilnost i realokaciju radne snage (13 zemalja)
- Državni udjeli u dionicama poduzeća (9 zemalja)
- Preferencijalni tretman u dobivanju ugovora za poslove s državom (8 zemalja)
- Pomoć za obuku radne snage (13 zemalja), itd.

Nakon ovoga kratkog povijesnog pregleda glavnih regionalnih poticaja u zemljama OECD-a vraćamo se recentnim radovima OECD-a koji nam pružaju korisne, puno kompleksnije smjernice.

Istraživanja upućuju na zaključak da su procesi u cijeloj državi ključni za perspektive rasta gradova, lokalnih zajednica i regija. OECD (2009) je utvrdio da su više regionalne stope rasta povezane s visokim nacionalnim stopama rasta i da uzročnost – bilo da regionalni učinak utječe na nacionalni rast ili obrnuto – djeluje u oba smjera. Osim toga, regije s visokim BDP-om rijetko bilježe negativne stope rasta (OECD, 2009:31). U regijama koje sporo rastu ili su u opadanju, djeluju drugi procesi, a lokalni čimbenici kao što su pad produktivnosti radne snage, povećanje stope nezaposlenosti, pad postotka stanovništva koji traži posao i nepovoljna demografija pridonose tom opadanju.

Važna spoznaja je da različiti procesi utječu na regije visokog i niskog rasta OECD (2009). Mjesta u kojima se gospodarstvo relativno brzo razvijalo imala su koristi od rasta stanovništva i povećanja produktivnosti rada – često kao posljedica ulaganja u nove tehnologije. Suprotno tome, regije koje su zaostale karakterizirao je pad broja stanovnika, pad udjela ekonomski aktivne radne snage i pad produktivnosti. Veća je vjerojatnost da su zaostale regije pretežno ruralne, a ne urbane. Ova studija je zaključila da će rast

vjerojatno biti znatno otežan u situacijama kada je raspoloživa radna snaga pod utjecajem demografskih promjena, poput starenja stanovništva ili rasta stope nezaposlenosti. Najnepovoljniji ishod nastaje kada se stopa nezaposlenosti povećava istodobno s povećanim izlaskom iz svijeta rada zbog odlaska u mirovinu te uvjerenja da se posao ne može naći ili iz drugih razloga.

Ruralne i urbane regije bitno se razlikuju s obzirom na dinamiku i mogućnosti rasta. Mnoge regije i lokalne zajednice diljem razvijenih zemalja i zemalja u razvoju ostaju čvrsto ukorijenjene u poljoprivredi i s njom povezanim industrijama. Takva se mjesta često suočavaju sa značajnim izazovima jer su prihodi obično manji, stope rasta niže i mnogi ključni pokazatelji zdravlja i blagostanja nisu tako povoljni u usporedbi s gradovima. Jedna od kritičnih prepreka je što ruralne regije istodobno pogađaju procesi koji su prisutni u svim dijelovima ekonomije, a dodatno su podložne dodatnim, specifičnim ekonomskim silama. Zbog toga je OECD 2006. godine razvio skup načela za ruralne regije koje je nazvao Nova ruralna paradigma (*New Rural Paradigm*). Ova paradigma pokušava uravnotežiti specifična obilježja ruralnih regija sa širim ekonomskim procesima. Prema toj paradigmi strategije razvoja ruralnih regija obično uključuju:

- Diversifikaciju ruralnih gospodarstava;
- Unapređenje prometnih i infrastrukturnih veza;
- Usvajanje boljih tehnologija za postizanje i održavanje konkurentске prednosti na globalnim tržištima;
- Pružanje obuke i treninga radi poboljšanja ljudskog kapitala i produktivnosti;
- Restrukturiranje poljoprivrednih industrija;
- Pronalaženje novih i učinkovitijih načina pružanja javnih usluga.

Ove strategije podrazumijevaju praksu lokalnog ekonomskog razvoja s jasnom orijentacijom na povezivanje s globalnim tržištima, uključivanje u odgovarajuće sustave inovacija, učinkovito upravljanje resursima na način koji otvara mogućnost za diversifikaciju ekonomije i poboljšanje vještina radne snage.

U modeliranju dinamike rasta OECD (2010) se usredotočio na tri ključna čimbenika koje je smatrao ključnima za razumijevanje ekonomskog rasta na

regionalnoj razini: (a) javni kapital ili infrastrukturu, (b) ljudski kapital i (c) inovacije. Ono što je veoma važno za našu studiju slučaja, ova studija OECD-a je prepoznala da je utjecaj navedenih čimbenika na rast relativno spor, odnosno da su to **čimbenici dugog roka**. Ulaganjima u infrastrukturu i obrazovanje potrebne su najmanje tri godine da izvrše mjerljiv utjecaj na rast, a za učinak ulaganja u inovacije treba još više vremena. Razmjerno dugo razdoblje između ulaganja u kapacitet zajednice i ishoda ne iznenađuje ni praktičare ni istraživače, ali pruža važnu lekciju za slučajeve potrebe izazivanja relativno brzih promjena kao što je slučaj Sisačko-moslavačke županije. Bez brzih promjena u pogledu povećanja stope rasta, zaposlenosti i dohotka u toj će regiji devastirajući demografski procesi napredovati do razine s koje neće biti moguć preokret. U tom smislu važan je i konkretan nalaz studije (OECD, 2009:69) da *"regije s nedostatnim ljudskim kapitalom neće rasti"*. A promatrana županija suočena je s dugoročnim trendom depopulacije, stalnim smanjenjem radno sposobne populacije i starenjem stanovništva do razine nemogućnosti biološke obnove.

Studija OECD-a (2009, 2012a i b) prepoznala je udaljenost od tržišta kao važan čimbenik za proces lokalnog rasta. Taj čimbenik ima nešto slabiji utjecaj u usporedbi s količinom i kvalitetom radne snage i razinom inovacije. Međutim, mjesta s dobrim pristupom tržištima imaju konkurentsku prednost u usporedbi s lokalnim zajednicama koje su prostorno udaljene od većih tržišta. To je osobito važno za lokalne zajednice s malim i nerazvijenim lokalnim tržištem. Blizina veće aglomeracije i dobra međusobna povezanost pomaže ne samo kroz veću potražnju za robama i uslugama nego i kroz prelijevanje znanja i inovacija. Ponekad se razvoj autonomno prelijeva iz većeg središta pa ključno pitanje nije hoće li doći do rasta, nego kakva je kvaliteta tog rasta.

Studija OECD-a (2012a) utvrdila je, suprotno očekivanjima, da politike koje su usmjerene na rast infrastrukture nisu najučinkovitije strategije za promicanje rasta zaostalih regija. Infrastruktura je prepoznata kao važan pokretač rasta u brzorastućim regijama, ali je ona relativno nevažna u regijama s niskim rastom. Zbog toga se preporučuje da se politika rasta infrastrukture dobro kombinira s ostalim politikama jer tek u tom slučaju, često veoma skupa infrastruktura, može ostvariti punu korist.

Studije OECD-a su utvrdile da je kritični čimbenik za regionalni i lokalni rast dobro upravljanje i dobra lokalna politika. Studija OECD-a (2012b) ističe važnost prihvaćanja etosa usmjerenog na rast koji svjesno nastoji

potaknuti razvoj, a to je uloga lokalne politike i lokalnog vodstva. Zanimljiv je rang glavnih prepreka rastu zaostalih regija koji se razlikuje od prepreka rastu brzo rastućih regija. Među glavne prepreke za rast u nerazvijenim regijama ubrajaju se redom sljedeće: (1) Institucije, uključivo vodstvo; (2) Lokalna politika; (3) Gustoća i kohezija stanovništva; (4) Količina i kvaliteta ljudskog kapitala; (5) Geografija; (6) Dostupnost infrastrukture; (7) Poslovno okruženje; (8) Demografski čimbenici; (9) Inovacije – uključujući i poduzetništvo.

Važna lekcija brojnih istraživanja o regionalnom rastu je da se rast bolje postiže uz sveobuhvatnu strategiju nego s pojedinačnim projektima. Jednokratna ulaganja u razvoj regija – poput izgradnje autocesta – prečesto imaju negativne posljedice. Takve će mjere vjerojatno rezultirati istjecanjem gospodarskih aktivnosti iz regije jer nisu povezane sa širim skupom mjera namijenjenih zadržavanju i širenju poslovanja u regiji.

Također je važan uvid OECD-a u planiranju rasta spoznaja da se strategije koje se koriste razlikuju ovisno o lokaciji i stupnju razvoja koji je već prisutan u toj zajednici. OECD (2012a) je razlikovao strategije potrebne za održavanje rasta u brzorastućim mjestima i one potrebne u mjestima koja opadaju ili rastu sporije. Kritički, iz perspektive OECD-a (2012a), "važno je razmišljati u okviru paketa politika a ne dijelova". U osnovi putevi k ostvarenju gospodarskog rasta su poznati i ostvarivi, a uključuju koordinirani pristup koji se bavi uklanjanjem prepreka za rast na svim područjima.

I na kraju ovog poglavlja korisno je pozornost usmjeriti na ideju o postojanju "četiri zlatna pravila regionalnog rasta" u 21. stoljeću kako ih je definirao Polese (2010). On ih definira na sljedeći način:

- 1) Veličina je važna jer se dinamičke industrije prirodno privlače u velike gradove ili mjesta s raznolikom industrijskom bazom, obrazovanom radnom snagom te koja su bogata prirodnim ili arhitektonskim nasljedom;
- 2) Lokacija je važna jer se industrije privlače na mjesta koja su najprikladnija za trgovinu i interakciju s tržištima;
- 3) Troškovi su važni jer će u nedostatku dvaju prethodnih čimbenika brže rasti mjesta koja posjeduju troškovne prednosti ili raspolazu obiljem resursa; ali

- 4) Postoje iznimke jer jedinstveni događaji poput nesreća (prirodne katastrofe, ratovi) – tehnoloških promjena, povijesti, politike – mogu uzrokovati rast ili pad unatoč prisutnosti triju prethodnih čimbenika.

Prethodno razmatranje pruža niz važnih spoznaja koje su potvrđene empirijskim istraživanjima pa mogu biti dobro polazište za definiranje učinkovite strategije gospodarske revitalizacije područja sa specifičnostima koje posjeduje Sisačko-moslavačka županija čije gospodarstvo je u fokusu ovog rada. Da bi se moglo pristupiti analizi odnosno izboru mogućih strategija, potrebno je analizirati trendove i stanje u gospodarstvu te regije, a što će biti učinjeno u idućem poglavlju.


3. OCJENA DOSTIGNUTE RAZINE I TRENDOVA GOSPODARSKE RAZVIJENOSTI SISAČKO-MOSLAVAČKE ŽUPANIJE

3.1. Prostor i stanovništvo

Sisačko-moslavačka županija se u ovom radu tretira kao poseban slučaj nerazvijene opadajuće regije pogođene katastrofalnim potresom te suočene s nizom egzogenih šokova (rat, potres, koronavirus). Iako potresom nije pogođeno cijelo područje, za potrebe definiranja temeljnih zaključaka o gospodarskim trendovima i stanju na potpomognutim područjima uzima se cijela Županija.

Prostor Sisačko-moslavačke županije obuhvaća 4.468 km², što čini 7,9% kopnene površine Republike Hrvatske. Stanovništvo Županije živi u 7 gradova, 12 općina i 455 naselja (31.12.2017.). Zatečena gustoća naseljenosti u Županiji je 38,6 stanovnika na km², što je gotovo dvostruko manje od prosjeka Republike Hrvatske (75,7).

Slika 1. Broj iseljenih iz Sisačko-moslavačke županije u razdoblju 2001. – 2018. godine



Izvor: Stanovništvo – pregled po županijama, DZS.

Prema popisu stanovništva iz 1991. godine na području Županije bilo je 251.332 stanovnika, dok je prema procjeni Državnog zavoda za statistiku za 1.1.2020. na području Županije bilo 144.599 stanovnika. U tridesetogodišnjem razdoblju broj stanovnika smanjen je za više od 100.000 ili za 42%. Od ulaska u Europsku uniju 2013. godine do početka 2020. godine, u Županiji je zabilježeno smanjenje broja stanovnika za 23.630 osoba. Dominantan razlog pada broja stanovnika nakon ulaska u Europsku uniju jest iseljavanje iz Sisačko-moslavačke županije, ili u inozemstvo ili u druge hrvatske županije.

U razdoblju od 2001. do 2019. godine pad broja stanovnika iznosi -43.598 ili čak 23,8%, što je najveći pad od svih županija u Republici Hrvatskoj. To je gotovo pet puta brži tempo pada broja stanovnika (-23,8%) od prosjeka Republike Hrvatske (-5%) u istom razdoblju uz napomenu da se pad broja

stanovnika prema kraju navedenog razdoblja ubrzava. Postotna promjena broja stanovnika po općinama i gradovima Sisačko-moslavačke županije upućuje na zaključak da su upravo gradovi i općine pogođene potresom bile izložene najvećoj depopulaciji.

U razdoblju od 2011. do 2019. godine najviše odseljenih stanovnika imaju Sisak (10.018) i Petrinja (7.807). Ova dva grada u istom razdoblju imaju i najveći broj odseljenih u inozemstvo, ali s promijenjenim redoslijedom, Petrinja (3.225), a Sisak (3.156). Relativni odnosi mjereni postotkom odseljenih u ukupnom broju stanovnika pokazuju realniju sliku problema i koncentriraju ga u većinu gradova i općina pogođenih potresom (Petrinja, Jasenovac, Hrvatska Dubica, Topusko, Sunja, Glina, Majur, Dvor, Gvozd, Hrvatska Kostajnica, Donji Kukuruzari). Većina tih naselja ima značajno veću prosječnu stopu iseljavanja od prosjeka Sisačko-moslavačke županije.

Doprinos negativnim neto migracijama tom padu je dvotrećinski, a tek jednu trećinu moguće je pripisati negativnom prirodnom prirastu. Kao što pokazuje prosječna vrijednost vitalnog indeksa od 52, u tom razdoblju u Županiji je svake godine dvostruko više ljudi umrlo nego se djece rodilo. U Sisačko-moslavačkoj županiji danas živi oko 70% više starijih osoba u dobi od 65 i više godina nego djece mlađe od 15 godina. Udio starijih u ukupnom stanovništvu je veći od 23% i iznad je prosjeka Republike Hrvatske. Prosječna starost stanovništva je 47 godina, a Eurostat prognozira da će do 2050. godine narasti na 52 godine. Eurostat također Sisačko-moslavačkoj županiji prognozira pad broja stanovnika na 88.175 do 2050. godine, odnosno za oko 39% u odnosu na danas. Po tome je Sisačko-moslavačka županija među demografski najugroženijim područjima Republike Hrvatske. Ono što generira daljnje smanjenje broja stanovnika, uz dinamičan trend iseljavanja, jest nepovoljna dobna struktura stanovništva. Pesimistični demografski trendovi u budućnosti ove Županije zadani su zatečenom dobnom strukturom stanovništva.¹⁰

Kada se nepovoljnim demografskim trendovima pridodaju i različiti socio-ekonomski problemi ovog područja te sve jači trendovi urbanizacije i centralizacije, nestanak čitavih ruralnih područja i drugi nepovoljni procesi, postoji opravdana bojazan za potpuno demografsko izumiranje najvećeg dijela ove Županije. To se posebno odnosi na ruralna i slabo razvijena

¹⁰ Zahvaljujem kolegi izv. prof. dr. sc. Ivanu Čipinu za podijeljene podatke o demografskim trendovima.

područja čija je depopulacija obilježena nižim stopama nataliteta, većim udjelom muškog stanovništva koji je posljedica veće emigracije žena (primarno zbog manjka poslova za žene), obrazovnim jazom između ruralnih i urbanih područja te velikim udjelom starijeg stanovništva. Iz navedenog se sam po sebi nameće zaključak da ne postoji jedno univerzalno rješenje problema te da se navedeni procesi koji su se kumulirali i produbljivali desetljećima neće moći zaustaviti i preokrenuti u jednom kratkom trenutku. Egzogene političke i ekonomske intervencije moraju uzeti u obzir raznolikost pojedinih mikropodručja i lokalne specifičnosti. Potrebne su precizne evaluacije da bi se identificirali oni aspekti koji bi mogli pogodovati demografskoj i ekonomskoj otpornosti.

3.2. Bruto domaći proizvod


Prema zadnjim dostupnim podacima Državnog zavoda za statistiku za razinu županija (2018.) u Sisačko-moslavačkoj županiji ostvaren je bruto domaći proizvod (BDP) od 9,8 milijardi kuna, što je svega 2,6% ukupnog BDP-a Republike Hrvatske. Taj udio je 2000. godine bio 3,9% da bi se dugoročno smanjio na 2,6%, što upućuje na zaključak o dugoročnom zaostajanju Sisačko-moslavačke županije u odnosu na Republiku Hrvatsku. Udio BDP-a Županije u ukupnom BDP-u Republike Hrvatske je značajno manji od udjela Sisačko-moslavačke županije u broju stanovnika (3,6%) i tri puta manje od udjela u površini Republike Hrvatske (7,9%). Od 2011. do 2018. godine (do kada postoje objavljeni podaci) ostvaren je kontinuirani trend pada BDP-a županije po prosječnoj godišnjoj stopi od -1%. Republika Hrvatska u istom razdoblju ostvarila je rast BDP-a po prosječnoj godišnjoj stopi od 2%.

Ako promotrimo promjene BDP-a po županijama Republike Hrvatske u dugoročnom razdoblju od 2001. do 2018. godine, Sisačko-moslavačka županija ostvarila je najveće smanjenje BDP-a u odnosu na sve druge županije. To znači da je divergencija Županije u odnosu na Republiku Hrvatsku prisutna u dugom roku.

Promatrano prema dva najvažnija razvojna indikatora, bruto domaćem proizvodu i ukupnom broju stanovnika, Sisačko-moslavačka županija je u dugoročnom razdoblju (2001. – 2018.) ostvarila po oba indikatora najlošiji rezultat u odnosu na sve županije. To je zorno vidljivo na sljedećoj slici koja

prikazuje promjenu udjela županija u broju stanovnika i u BDP-u Republike Hrvatske.

Slika 2. Udio bruto domaćeg proizvoda Sisačko-moslavačke županije u ukupnom BDP-u Republike Hrvatske u %, 2000. – 2018. godine




Izvor: DZS, obrada autora.

Prema ova dva kombinirana pokazatelja najveći pad je ostvarila Sisačko-moslavačka županija, a najveći porast Grad Zagreb. Ostale županije grupirane su u grozdove u prvom i trećem kvadrantu. Iz navedenog prikaza može se općenito zaključiti da županije koje ostvaruju porast udjela BDP-a, što implicira brži rast BDP-a od državnog prosjeka imaju i porast broja stanovnika. I obrnuto, županije s ispodprosječnom stopom rasta BDP-a istodobno ostvaruju i pad broja stanovnika. Radi se o veoma čvrstoj korelaciji ($R^2 = 0,76$). Drugim riječima, ako se u Sisačko-moslavačkoj županiji bar dugoročno želi ostvariti konvergencija s prosjecima Republike Hrvatske, u kratkom i srednjem roku je nužno poduzeti različite mjere

ekonomske i razvojne politike koje će **značajno ubrzati stopu rasta BDP-a** Županije iznad prosjeka Republike Hrvatske.

Slika 3. Promjena udjela županija u broju stanovnika i BDP-u Republike Hrvatske, 2001. – 2018. godine



Izvor: DZS, obrada autora.

U kontekstu zacrtanih ciljeva "*Nacionalne razvojne strategije Republike Hrvatske 2030.*", Sisačko-moslavačka županija bi za dostizanje prosjeka BDP-a po stanovniku RH do 2030. godine morala ostvarivati veoma visoku stopu rasta veću od 6% (uz pretpostavku nepromijenjenog broja stanovnika). Ako u idućem desetljeću očekujemo i povećanje broja stanovnika za 1% prosječno godišnje, onda je za toliko potrebna veća prosječna stopa rasta BDP-a. Dakle, u ovom kontekstu, konvergenzijska stopa rasta trebala bi iznositi oko 7%, što je iznimno visoka stopa za čije dostizanje je potrebna dodatna akumulacija i snažno egzogeno poticanje investicija.


Komparativno promatrano, Sisačko-moslavačka županija je na razini 42,9% standarda Europske unije (2018.), dok je Republika Hrvatska na razini od 66,8% Europske unije, što znači da Županija značajno zaostaje i pripada skupini najmanje razvijenih NUTS 3 regija u Europskoj uniji. Pad standarda, mjeran udjelom BDP-a po stanovniku po standardu kupovne moći (EU27 = 100), u Županiji je prisutan dugoročno. U vrijeme zadnje Velike recesije i financijske krize udio tog pokazatelja za Sisačko-moslavačku županiju bio je 48,5%, da bi se kontinuirano smanjivao na 42,9% (2018.), što znači da se po tom pokazatelju također ostvaruju dugoročni trendovi divergencije.

3.3. Gospodarstvo Sisačko-moslavačke županije

Prema podacima FINA-e u 2019. godini na području Sisačko-moslavačke županije bilo je 2.308 poduzetnika. Od toga čak 594 poduzetnika ili 25,7% nisu imali zaposlenih. Gustoća poduzetnika mjerena brojem poduzeća na km² iznosila je 0,5 poduzeća/km², što je otprilike pet puta manje od prosjeka Republike Hrvatske. Gustoća poduzetnika mjerena brojem poduzeća na 1.000 stanovnika iznosila je 16, što je dvostruko manje od prosjeka Republike Hrvatske (33,6). Iz ovih se podataka može zaključiti da je gustoća poduzetnika u Sisačko-moslavačkoj županiji iznimno niska te da se radi o prostoru koji je iznimno deficitaran poduzetničkim aktivnostima i slabom poduzetničkom klimom. Prostorna distribucija pokazatelja gustoće poduzetništva pokazuje da je taj pokazatelj u svim gradovima i općinama županije znatno ispod prosjeka Republike Hrvatske. Od ukupnog broja poduzeća čak 68% (više od dvije trećine) je locirano na potresom pogođenom području Županije, i to 56% u gradovima i 12% u općinama.

Prema podacima financijskih izvješća poduzetnika koje obrađuje FINA, 2019. godine u poduzećima u Sisačko-moslavačkoj županiji bile su zaposlene 18.473 osobe (na bazi sati rada). To je još uvijek 12,5% manje nego što je bilo 2008. godine (prije početka svjetske financijske krize). Dugoročni trendovi zaposlenosti (2008. – 2009.) u Županiji pokazuju značajno zaostajanje u odnosu na Republiku Hrvatsku gdje je predkrizna razina zaposlenosti dostignuta 2018. godine, što je prikazano na sljedećoj slici. Zaposleni u poduzećima koncentrirani su u tri najveća grada (Sisak, Kutina, Petrinja) gdje je 72% ili skoro tri četvrtine ukupno zaposlenih na području Županije.

**Slika 4. Indeks promjene broja zaposlenih u poduzećima
SMŽ i RH, 2008 = 100**



Izvor: FINA, obrada autora.

Prethodni dio analize ograničen je na broj zaposlenih samo kod poduzetnika koji su obveznici poreza na dobit i koji predaju financijska izvješća FINA-i. Zbog toga se u idućem poglavlju prikazuje analiza ukupnog broja zaposlenih u svim pravnim osobama u Sisačko-moslavačkoj županiji, a taj broj je 2019. godine iznosio 32.179 osoba.¹¹


3.3.1. Analiza konkurentnosti gospodarstva Sisačko-moslavačke županije

Podaci o ukupnom broju zaposlenih kod svih pravnih osoba omogućuju nam veoma informativnu analizu specijalizacije ukupnoga gospodarstva Županije pomoću metode lokacijskih kvocijenata (LQ) te analizu lokalne

¹¹ Razlika između broja zaposlenih kod poduzetnika i ukupnog broja zaposlenih u Županiji iznosi 13.706 zaposlenih, što se dominantno odnosi na ustanove i druge pravne osobe koje nisu obveznici poreza na dobit.

konkurentnosti pomoću *shift-share* analize (analize pomaka udjela). Rezultate navedenih analiza moguće je koristiti za pouzdanu ocjenu sektorske strukture lokalnoga gospodarstva te odvajanje konkurentnih od nekonkurentnih sektora i ocjenu utjecaja lokalne konkurentnosti u odnosu na utjecaj strukture gospodarstva (*mix komponenta*) i utjecaja tzv. nacionalne komponente.

Slika 5. Lokacijski kvocijenti Sisačko-moslavačke županije, 2019. godine



Izvor: FINA, izračun i obrada autora.

Rezultati analize pomoću metode lokacijskih kvocijenata (LQ) upućuju na postojanje velikih strukturnih neravnoteža gospodarstva Sisačko-moslavačke županije i posebno na problem tzv. "strukturne rupe". Interpretacija rezultata na slici 5. polazi od horizontalne crvene iscrtane linije koja pokazuje vrijednost $LQ = 1$.¹² Ta vrijednost ($LQ = 1$) znači da je

¹² Uvjetno rečeno, idealna struktura bi bila kada bi svi sektori imali $LQ = 1$. To bi vrijedilo uz uvjet da su svi sektori na nacionalnoj razini konkurentni. Međutim, u stvarnosti takva pretpostavka je ipak nerealna pa to treba imati u vidu kod interpretacije rezultata metode lokacijskih kvocijenata. To je svakako i jedno od ograničenja metode.

sektor s takvom vrijednosti specijaliziran točno na razini prosjeka Republike Hrvatske. Vrijednosti $LQ > 1$ predstavljaju sektore u kojima je gospodarstvo Županije više specijalizirano u odnosu na Republiku Hrvatsku i obrnuto, vrijednosti $LQ < 1$ predstavljaju sektore koji su manje specijalizirani u odnosu na Republiku Hrvatsku.

Rezultati pokazuju da je gospodarstvo Županije (2019.) specijalizirano ($LQ > 1$) u prerađivačkoj industriji (C), poljoprivredi i šumarstvu (A) te rudarstvu i vađenju (B). To su tzv. "*tradable*" sektori odnosno sektori čiji se output realizira na tržištu, što znači da su sektori pod utjecajem konkurentskih tržišnih sila. Pored ovih sektora, lokacijski koeficijent veći od jedan imaju i brojni sektori koje nazivamo "*nontradable*" odnosno sektori čiji se output ne realizira na tržištu i ne može se međunarodno razmjenjivati. To su sektori u kojima dominiraju javna poduzeća te ustanove čiji se prihodi formiraju dominantno proračunskim transferima. Popis tih sektora prikazan je na desnoj strani slike. U Republici Hrvatskoj u većini županija, osim Grada Zagreba, u strukturi dominiraju sektori javnih usluga (električna energija, plin, voda, gospodarenje otpadom) te posebno javna uprava, obrazovanje i zdravstvo, pa Sisačko-moslavačka županija u tom pogledu nije iznimka. To je očito odraz dugoročnog nešto bržeg i "lakšeg" zapošljavanja u javnom sektoru koji nije pod utjecajem tržišta odnosno čije upravljanje nedovoljno slijedi logiku rasta produktivnosti i ekonomičnosti.

U razvojnog smislu najveći potencijal Sisačko-moslavačke županije (uz sektor prerađivačke industrije i poljoprivrede) nalazi se u sektorima koji su na slici definirani kao "*strukturna rupa*" i koji trenutno imaju $LQ < 1$. Radi se o manje razvijenim sektorima u odnosu na nacionalni prosjek, a među kojima se uz neke tradicionalne nalaze i gotovo svi moderni propulzivni sektori. Najmanje zastupljen sektor u županijskom gospodarstvu je sektor *informacija i komunikacija* (J) kojeg u pravilu čine telekomunikacije i informatička industrija koji se ubrajaju u najpropulzivnije sektore u svijetu. Zanimljivo je da ga slijedi sektor *smještaja i pripreme hrane* (I) koji je peterostruko manje razvijen od državnog prosjeka iako je turizam već dva desetljeća označen kao strateški razvojni pravac Županije (postoji i posebna strategija razvoja turizma SMŽ). To ujedno upućuje na činjenicu da se dosadašnja glavna strateška opredjeljenja zapravo ne ostvaruju ili se slabo ostvaruju. U slabo razvijene, a moderne i u svijetu rastuće sektore, na području Županije ubraja se i sektor *stručnih, znanstvenih i tehničkih usluga* (M) te *administrativnih i pomoćnih usluga* (N). Ako tome dodamo i slabo razvijene sektore *financija i osiguranja* (K), *poslovanja nekretninama* (L) te

sektor *umjetnosti, zabave i rekreacije* (R), postaje jasno da takvo gospodarstvo ne nudi dovoljan broj radnih mjesta za mlade i obrazovane osobe pa je zapravo sasvim razumljiv njihov dugoročni trend iseljavanja.

Podaci i analiza nedvojbeno ukazuju na potrebu upravljanja i poticanja promjene sektorske strukture gospodarstva Sisačko-moslavačke županije prema sektoru modernih usluga, što je zapravo uvjet zadržavanja i/ili privlačenja mlade i obrazovane radne snage na područje Županije.

Za potrebe dubljeg uvida u lokalnu konkurentnost izrađena je *shift-share* analiza¹³ gospodarstva Sisačko-moslavačke županije koja nam u kombinaciji s metodom lokacijskih kvocijenata omogućuje donošenje pouzdanijih zaključaka¹⁴ o konkurentnosti lokalnoga gospodarstva te o izvorima (ne)konkurentnosti.

Zaključke ove analize najkraće možemo sažeti na sljedeće:

- Negativna lokalna komponenta zabilježena kod većine sektora, što upućuje na zaključak da *lokalni poslovni i drugi uvjeti nisu imali pozitivan utjecaj na razvoj*, odnosno upućuje na neuspjeh dosadašnjega lokalnog poticanja gospodarstva Županije;
- Negativna mix komponenta kod većine "*tradable*" (razmjenskih) sektora upućuje na zaključak da je *struktura lokalnoga gospodarstva nepovoljna* te da nije imala pozitivan utjecaj na promjene u promatranom razdoblju (2009. – 2019.);
- Jedino nacionalna komponenta ima pozitivnu vrijednost, i to kod svih sektora, što upućuje na zaključak da se *razvoj gospodarstva gotovo u cjelini odvijao pod utjecajem nacionalne ekonomske i razvojne politike*, odnosno da je nacionalna razina imala najveći utjecaj na ukupni i sektorski rast/pad.

3.3.2. Financijski rezultati poslovanja poduzetnika Sisačko-moslavačke županije

Poduzetnici Sisačko-moslavačke županije su 2019. godine ostvarili ukupan prihod u iznosu od 10,9 milijardi kuna te ukupne rashode u iznosu od 10,5


¹³ Više o *shift-share* analizi vidi u (Čavrak, 2012). Detaljni rezultati analize nisu ovdje prikazani zbog duljine rada pa se zainteresirane čitatelje upućuje na kontakt s autorom.

¹⁴ *Shift-share* metoda također ima brojna ograničenja, ali zbog svoje jednostavnosti često se koristi za donošenje tzv. prvih aproksimacija.

milijardi kuna. Nakon šest godina ostvarivanja lošeg financijskog rezultata poslovanja i gubitaka, 2019. godine ostvaren je pozitivan konsolidirani financijski rezultat (dobitak) u iznosu od 348,8 milijuna kuna.

U 2019. godini poduzetnici Sisačko-moslavačke županije platili su 65,5 milijuna kuna poreza na dobit. Plaćeni porez na dobit, kumulativno u razdoblju 2011. – 2019. godine iznosio je 369,2 milijuna kuna.¹⁵

**Slika 6. Konsolidirani financijski rezultat poduzetnika
Sisačko-moslavačke županije, 2008. – 2019. godine**



Izvor: FINA, obrada autora.


Prosječne neto plaće kod poduzetnika u Sisačko-moslavačkoj županiji dugoročno su niže od nacionalnog prosjeka za oko -20%, što ima značajan limitirajući utjecaj na formiranje opsega lokalnog tržišta. U 2019. godini neto plaće kod poduzetnika u Županiji iznosile su svega 4.660 kuna (u Republici Hrvatskoj neto plaće su iznosile 5.815 kuna). Međutim, kada analiziramo neto

¹⁵ U slučaju donošenja fiskalne mjere 100% oslobođenja od poreza na dobit za poduzetnike SMŽ, to bi bio orijentacijski gubitak za proračun Republike Hrvatske koji ne bi imao značajnijeg odraza na stabilnost državnog proračuna.

plaće kod poduzetnika u općinama i gradovima, možemo zaključiti da su neto plaće kod poduzetnika u velikom broju gradova i općina ispod prosjeka Županije. Posebno zabrinjava nizak iznos prosječne neto plaće kod poduzetnika u Sisku koji je među najmanjima u Županiji i 2019. godine je iznosio svega 4.260 kuna, što je čak -27% manje od nacionalnog prosjeka (a u Sisku je koncentrirano oko 33% svih zaposlenih u Županiji).

Analiza strukture ostvarenih ukupnih prihoda poduzetnika u Sisačko-moslavačkoj županiji upućuje na slabu izvoznu orijentaciju. Od ukupno 2.308 poduzetnika samo njih 321 ili 13,9% ostvaruje ukupne prihode od izvoza (2019.), što je ispod prosjeka Republike Hrvatske (15%). Dugoročni trend izvozne orijentacije, mjereno udjelom prihoda od izvoza u ukupnim prihodima je negativan (-1,8% prosječno godišnje od 2014. do 2019.).

Slika 7. Udio izvoza u ukupnim prihodima poduzetnika u %, 2019. godine




Izvor: FINA, izračun i obrada autora.

Posebno je zabrinjavajuć iznimno nizak udio izvoznih prihoda kod poduzetnika na području najvećih gradova, Siska (9,1%) i Petrinje (12,3%) koji zapošljavaju 43% ukupno zaposlenih u županijskom gospodarstvu.

Ove podatke vjerojatno treba interpretirati u kontekstu postojanja *strukturne rupe* kao i dugogodišnje devastacije sektora prerađivačke industrije u Sisku i Petrinji.

Analiza poslovanja poduzetnika u Sisačko-moslavačkoj županiji upućuje na osobito velik problem relativno skromnih iznosa sredstava koja se investiraju u novu dugotrajnu imovinu. Zbog toga se ne uspijeva ostvariti modernizacija gospodarstva i ne uspijeva se postići zadovoljavajući trend otvaranja novih radnih mjesta, posebno za mlade i obrazovane. U 2019. godini poduzetnici na području županije investirali su u novu dugotrajnu imovinu svega 231,6 milijuna kuna, što čini 2,1% ukupnih prihoda. U istoj godini poduzetnici u Republici Hrvatskoj investirali su u novu dugotrajnu imovinu 3,5% ukupnih prihoda. To znači da poduzetnici u Županiji investiraju oko -40% manje nego poduzetnici u Republici Hrvatskoj. Posebnu pozornost treba posvetiti podatku da samo jedan od deset poduzetnika (10%) investira u novu dugotrajnu imovinu. U dugom roku (2008. – 2019.) investicije u novu dugotrajnu imovinu svih poduzetnika Sisačko-moslavačke županije opadaju po prosječnoj godišnjoj stopi od -7,85%. To upućuje na dugoročni trend smanjivanja proizvodnih mogućnosti i razvojnih potencijala.

**Slika 8. Investicije u novu dugotrajnu imovinu, poduzetnici
Sisačko-moslavačke županije, 2008. – 2019. godine, tis. kuna**



Izvor: FINA, izračun i obrada autora.

Kompletiranju slike nepovoljnih trendova i stanja Sisačko-moslavačke županije moglo bi se pridodati još mnoštvo drugih činjenica, ali se glavni zaključci time ne bi promijenili. Zbog toga ćemo samo još konstatirati činjenicu postojanja skromnih fiskalnih kapaciteta jedinica lokalne i područne (regionalne) samouprave koji su dodatno smanjeni u vrijeme prisutnosti koronavirusa, a osobito nakon potresa. Možda to stanje najbolje oslikava podatak o niskoj razini i enormnom padu fiskalnih prihoda Sisačko-moslavačke županije u 2020. godini. Prihodi od poreza na dohodak najznačajniji su prihod županija. Sisačko-moslavačka županija, uz Virovitičko-podravsku, ima najmanji udio poreza na dohodak u ukupnim prihodima, i to oko 20 posto, ali i najveći pad tih prihoda u 2020. godini. Ti su se prihodi smanjili čak za jednu trećinu, što je najveći pad među hrvatskim županijama. Za usporedbu, kod razvijenih županija prihodi od poreza na dohodak čine 40 pa i preko 60 posto fiskalnih prihoda (Grad


Zagreb čak 66,8 posto).¹⁶ Ti podaci sasvim jasno ukazuju na razlike u dohocima između županija, a koje s jedne strane indiciraju različite razine gospodarske aktivnosti stanovništva, a s druge strane enormne razlike u dohocima stanovništva. Iz toga se može pouzdano zaključiti i o velikim razlikama u opsegu kupovne moći te ekonomskom blagostanju i snazi stanovništva.

U ovom kontekstu je zanimljiv i podatak o cijenama nekretnina, odnosno razlikama tih cijena između Sisačko-moslavačke županije i razvijenih županija na Jadranu i Grada Zagreba. U gradovima i općinama Sisačko-moslavačke županije (na primjer, Petrinja, Glina, Novska, Martinska Ves, Popovača, Jasenovac) medijalne cijene građevinskog zemljišta 2020. godine iznosile su manje od 10 kn po m². U isto vrijeme cijene u razvijenim županijama i na Jadranu iznosile su i preko 1.000 kn po m².¹⁷ To znači da je omjer cijena nekretnina na štetu područja Sisačko-moslavačke županije preko 1 : 100. To govori o enormnoj razlici u bogatstvu i potencijalnom bogatstvu građana i poslovnih subjekta. Za razliku od razvijenih dijelova Republike Hrvatske, nekretnine na području Sisačko-moslavačke županije su do te mjere obezvrijeđene da ne predstavljaju bogatstvo, nego često financijski teret jer iz također nižeg dohotka nema mogućnosti ni ulaganja u njihovo osnovno održavanje. Također kad je u pitanju mogućnost konverzije vrijednosti nekretnina u novac za pokretanje poslovanja, što je u tržišnom gospodarstvu uobičajen postupak, to na području Županije nije realan izvor jer su nekretnine praktično bezvrijedne i njihovim monetiziranjem se ne može doći do većih novčanih iznosa za investiranje u poslovanje ili za početak poslovanja. To je jedan od razloga male gustoće poduzetništva i slabe poduzetničke kulture. Navedeno potvrđuje i činjenica da banke u pravilu izbjegavaju prihvatiti garancije u nekretninama na tom području, a što se poljoprivrednog zemljišta tiče, takvih primjera gotovo da nema.

¹⁶ Vidi, Jurlina Alibegović, D. (ur.) *Porez na dohodak po županijama u 2020. godini*, Ekonomski institut Zagreb, Regio-novosti, broj 18, rujan 2021., str. 3-4.

¹⁷ Isto, str. 11.

Slika 9. Udio broja blokiranih građana u broju radno sposobnog stanovništva u %, stanje 31.12.2020. godine



Izvor: FINA, Očevidnik o redoslijedu osnova za plaćanje, stanje 31.12.2020.

Ovim činjenicama mogu se dodati i podaci o broju blokiranih građana gdje Sisačko-moslavačka županija drži prvo mjesto u Republici Hrvatskoj s najviše blokiranih. Prema podacima FINA-e u toj je županiji na dan 31.12.2020. godine svaki deseti radno sposobni građanin bio u blokadi (nemogućnosti izvršenja dospjelih obveza). Ukupan dug građana Županije iznosio je oko 570 milijuna kuna, što je otprilike ekvivalent četvero-mjesečnom ukupnom fondu neto plaća koje prime svi zaposleni na području Županije.

Ove činjenice i podaci zorno svjedoče o iznimno niskoj razini bogatstva i dohotka stanovništva, što uz dugogodišnje negativne financijske rezultate poslovanja poduzeća navodi na nedvojben zaključak o nepostojanju lokalnih i vlastitih izvora za financiranje investicija, odnosno da ne postoje lokalni izvori rasta. Sve nabrojeno ima važne ekonomske, ali i brojne socijalne, pa i političke posljedice koje nisu u fokusu ovog rada, ali na koje valja upozoriti.

3.4. Glavni zaključci analize trendova i stanja gospodarstva Sisačko-moslavačke županije

Na temelju prethodne analize trendova i stanja gospodarstva na području Sisačko-moslavačke županije, mogu se izvesti sljedeći zaključci:

- Dugoročni trend smanjivanja udjela BDP-a Županije u BDP-u Hrvatske
- Kontinuirani pad BDP-a (2012. – 2019.)
- U dugom razdoblju (2001. – 2017.) SMŽ ima najveći pad BDP-a i stanovnika od svih županija u RH, ima najnepovoljniju starosnu strukturu i stanovništvo koje nema uvjeta za biološku reprodukciju
- Iznimno niska razina standarda mjereno BDP-om po stanovniku prema standardu kupovne moći (42,8% EU=28) uz stalni trend pada ovog pokazatelja od 2012. godine
- Niska razina gustoće poduzetništva – slab poduzetnički kapacitet i potencijal
- Brži pad zaposlenosti (2008. – 2016.) i sporija dinamika rasta zaposlenosti (2017. – 2019.) u odnosu na RH
- Koncentracija zaposlenih u tri grada (Sisak, Kutina, Petrinja)
- Loša gospodarska struktura u kojoj dominiraju sektori koji ovise o proračunu i "nontradable" sektori s velikom "strukturnom rupom" i manjkom modernih propulzivnih sektora usluga
- U proizvodnim sektorima dominiraju poduzetnici s izvoznom orijentacijom koji su uspjeli zadržati inozemnu konkurentnost – to vrijedi isključivo za najveće poduzetnike
- Prosječno je mala izvozna orijentacija poduzetnika jer svega 13,9% ostvaruje izvoz
- Mala i srednja poduzeća više orijentirana na domaće i ograničeno lokalno tržište suočavaju se s problemom nekonkurentnosti
- Lokalni poslovni uvjeti i poticaji ne pridonose rastu konkurentnosti
- Financijski rezultati poslovanja poduzetnika u duljem roku (zadnjih sedam godina) su negativni (gubitak), i to u svim godinama osim 2019. kada je ostvarena mala dobit

- Prosječne neto plaće kod poduzetnika su u dugom roku oko 20% ispod državnog prosjeka, što značajno limitira obujam lokalnog tržišta i lokalnu potražnju (zbog toga su u dugom roku i mirovine u prosjeku niže od državnog prosjeka)
- Dugoročni pad investicija po prosječnoj godišnjoj stopi -7,85%, slaba kapitalna opremljenost, smanjivanje proizvodnih mogućnosti i pad razvojnog potencijala poduzetnika
- Najveći udio blokiranih u radno sposobnom stanovništvu, itd.

Prezentirani zaključci koji proizlaze iz empirijske analize morali bi biti osnovna polazna točka prilikom programiranja strategije i različitih programa obnove i gospodarske revitalizacije konkretnog područja. Navedenim zaključcima svakako treba pridodati i činjenicu da je područje Sisačko-moslavačke županije, uz navedeno, u relativno kratkom roku bilo izvrgnuto četirima egzogenim šokovima: (1) velikom razaranju tijekom obrambenog Domovinskog rata; (2) velikim troškovima tranzicije i nestanku brojnih industrijskih kapaciteta; (3) negativnom utjecaju pandemije COVID-19 i (4) višestrukim razornim potresima. Ukupne izravne, indirektna i inducirane štete od potresa i ostalih egzogenih šokova još nisu u cjelini procijenjene, a neke će biti vidljive tek u idućem razdoblju jer se događaju s vremenskim pomakom. Sve navedeno ukazuje na postojanje brojnih razlika i specifičnosti u ekonomskom položaju ove regije spram ostalih regija u Republici Hrvatskoj. To je ujedno razlog i uzrok potrebe postojanja različitog pristupa pri izradi razvojne i revitalizacijske strategije za ovo područje o čemu se piše u idućem poglavlju.

4. GLAVNI ELEMENTI STRATEGIJE GOSPODARSKE REVITALIZACIJE NERAZVIJENOG PODRUČJA POGOĐENOG POTRESOM

Pojam strategije¹⁸ ima širi obuhvat od pojma plan i ne radi se o sinonimima. Plan je dio strategije koji zapravo obuhvaća ciljeve, odnosno promjene koje se želi ostvariti u duljem roku. Drugi dio strategije obuhvaća taktiku odnosno način kako će se operativno zacrtani ciljevi ostvarivati. Treći dio

¹⁸ Prema Mintzbergu (1987) strategija obično obuhvaća takozvanih "pet p" prema početnim slovima riječi na engleskom jeziku: *a plan, a ploy, a pattern of behaviour, a position with respect to others, a perspective*.

strategije obuhvaća razradu obrazaca ponašanja aktera, odnosno varijabli koje su dio plana. Četvrti dio strategije obuhvaća procjenu položaja u odnosu na druge aktere, u našem slučaju područja (odnos lokalno – nacionalno, odnos prema drugim regijama) i procjenu promjene tih interakcija u budućnosti. I peti dio strategije je procjena budućih alternativnih scenarija te uspostava sustava koji će moći promptno reagirati na iznenadne pojave i promjene. Plan je relativno fiksni, a ukupna strategija uključuje elemente fleksibilnosti reakcije u vremenu. Zbog toga su različite strategije često općenite jer moraju omogućiti fleksibilne reakcije u tijeku njihova ostvarenja radi optimalnog svladavanja ne samo početnih prepreka nego i iznenadnih prepreka koje se nužno pojavljuju tijekom realizacije.

Jedna od presudnih komponenti za uspjeh strategije jest sposobnost i kapacitet glavnih nositelja da svladaju vremenski jaz koji se zapravo pojavljuje u tri aspekta, i to kao: (1) jaz spoznaje; (2) jaz formuliranja i donošenja strategije i (3) jaz primjene. Kad je u pitanju slučaj koji se razmatra u ovom radu, a to je Sisačko-moslavačka županija kao iznimno nerazvijeno i potresom pogođeno područje, možemo pretpostaviti da je vrijeme spoznaje bilo relativno kratko zbog drastičnih i vidljivih posljedica potresa. Međutim, jaz formuliranja i donošenja strategije zasad uzima prilično vremena bez jasne perspektive kada će konačna strategija biti usvojena. Ako se usvoji do kraja godine, to će značiti da je utrošeno punih godinu dana. Trajanje jaza primjene zasad je nemoguće procijeniti jer je nepoznato koja će se strategija izabrati i s kojim mjerama. A dok instrumenti i mjere nisu poznati, nemoguće je procijeniti kada će njihova primjena započeti, odnosno kada će biti vidljivi prvi učinci.

Da bi se formulirala učinkovita strategija, prvi korak koji treba učiniti jest definiranje temeljnih ciljeva koji se žele ostvariti. Ovdje polazimo od pretpostavke da se prostor Sisačko-moslavačke županije želi brzo regenerirati s ciljem zaustavljanja daljnje demografske devastacije te da se želi postići što brži rast gospodarskih aktivnosti, zaposlenosti i dohotka uz rast konkurentnosti, produktivnosti i inovacijskog potencijala.¹⁹ Ovi ciljevi

¹⁹ Ciljevi različitih razvojnih strategija mogu biti eksplicitni ili implicitni. Eksplicitni ciljevi gospodarske revitalizacije zasad službeno nisu definirani, a i kada se precizno definiraju, nije isključeno da mogu postojati i implicitni ili "skriveni" ciljevi. Znakovito je, na primjer, zapažanje da se zadnjih godina, možda čak i desetljeće, u prostoru Sisačko-moslavačke županije događa vrlo malo ili ništa investicija u području javne infrastrukture za koju je glavni nositelj centralna država s državnim poduzećima. Tako je na primjer autocesta Sisak – Zagreb prema prvom planu trebala biti završena još prije 2007. godine, a nije dovršena niti petnaest godina kasnije. Nije jasno znači li to da osim eksplicitne postoji i implicitna strategija.

su komplementarni cilju demografske revitalizacije jer stanovništvu prijeti izumiranje, a prostoru prijeti potpuno pražnjenje. Prethodni ciljevi su nužan preduvjet za stvaranje potencijala povećanja kvalitete života.

Zbog zatečene niske razine razvijenosti, skromnoga razvojnog potencijala i snažnog osjećaja besperspektivnosti stanovništva, kojeg dodatno pojačava iznimno spor proces obnove nakon potresa, naglasak pri definiranju ciljeva je na pojam "**brzo**". U ovom slučaju brzina ostvarivanja promjena i vidljivih učinaka je od primarne važnosti zbog psiholoških učinaka na odvrćanje, posebno mladih i obrazovanih osoba od namjere iseljavanja. U ovom trenutku nisu prisutni samo psihološki aspekti odluke za iseljavanje nego i ekonomski. Naime, zbog visoke razine siromaštva, male vrijednosti nekretnina i druge imovine u ovom prostoru u kombinaciji sa slabim očekivanjima, diskontirani ekonomski gubici odlaska i napuštanja te skromne i bezvrijedne imovine su manji od potencijalnih koristi i dobitaka od seljenja i življenja u razvijenim područjima Republike Hrvatske ili Europske unije koja uz to nude znatno veće životne prilike i pozitivna očekivanja. Ovo je inače dobar primjer važnosti uključivanja psiholoških varijabli, posebno očekivanja u modele rasta i lokalnog razvoja te važnosti vođenja računa o vremenskom aspektu poduzimanja adekvatnih mjera. Sporo poduzimanje mjera i izbor mjera koje daju vidljive rezultate u dugom roku za slučaj gospodarske i društvene revitalizacije ovakvog prostora nije dobar put.²⁰

Kako je do sada već prošlo devet mjeseci od potresa, a da još nije definirana strategija gospodarske i društvene revitalizacije niti njezine glavne nosive mjere te kako obnova urušenih stambenih i gospodarskih objekata zapravo još nije ni započela, a kamoli završena, sasvim je jasno da se nepovratno izgubilo dragocjeno vrijeme te da su se očekivanja stanovništva dodatno pogoršala. To znači da su dvije važne varijable, brzina i vrijeme, u značajnoj mjeri već iscrpljene, što dodatno komplicira daljnji proces definiranja i provođenja bilo kakve strategije.

²⁰ Ovaj tekst nastaje potkraj rujna 2021. godine, devet mjeseci iza potresa, u uvjetima u kojima se još ne nazire jasna strategija, a kamoli da se nazire trenutak u kojem bi bilo kakve mjere gospodarske revitalizacije polučile vidljive učinke. To znači da je već u ovom trenutku izgubljena mogućnost za brzo djelovanje. A ako se u međuvremenu prihvati i poduzme strategija s mjerama koje daju rezultate u srednjem ili dugom roku, sasvim je izvjesno da postoji opasnost izostanka bilo kakve revitalizacije u aktualnoj generaciji.

Sljedeće pitanje na koje treba odgovoriti je pitanje da li, kako i u kojoj mjeri poticati poduzetnike i poduzeća koja se već nalaze u prostoru Županije (endogeni razvoj) ili se fokusirati na privlačenje poduzetnika i poduzeća iz okruženja, iz Republike Hrvatske i inozemstva (egzogeni razvoj). Očito je da se moraju kombinirati oba pristupa.

Radi potrebe ostvarivanja brzih učinaka u prvoj fazi bi se morale dizajnirati mjere za zadržavanje i poticanje rasta postojećih poslovnih subjekata. Pritom se nezaobilazno mora poći od zaključka iz empirijskog dijela analize koji upućuju na problem dugotrajne financijske iscrpljenosti i slabe kapitalne opremljenosti većine zatečenih poslovnih subjekata. Zbog toga će biti nužna egzogena državna intervencija putem različitih mjera izravnih investicijskih poticaja, poreznih olakšica i poticaja do stvaranja preferencijalnih uvjeta pri kandidiranju poslovnih i drugih subjekata s ovog područja za sredstva iz fondova Europske unije, Nacionalnog programa oporavka i otpornosti i drugih.²¹

Strategija endogenog razvoja uključuje poduzimanje aktivnosti i mjera usmjerenih na razvoj poslovnih subjekata zatečenih na području lokalne zajednice i stvaranje uvjeta za povećanje šanse za njihov uspjeh i poboljšavanje poslovnih i financijskih rezultata poslovanja. Zauzvrat to će pridonijeti ukupnom prosperitetu regije i potaknuti stvaranje novih poslovnih subjekata. Zato ima opravdanja da se u lokalnoj zajednici stvaraju odnosi suradnje lokalnih vlasti i svih vrsta poslovnih subjekata. Postoji nekoliko pristupa poticanju endogenog lokalnog razvoja unutar kojih se može definirati mnoštvo strategija i aktivnosti koje su dostupne svakoj lokalnoj zajednici.

Jedna od mogućnosti je graditi strategiju povećanja atraktivnosti lokalne zajednice kako bi je se učinilo mjestom za profitabilnije poslovanje, preferirano mjesto za maloprodaju, distribuciju i slično. Razvojna literatura ovu strategiju definira kao strategiju koja se oslanja na mjere na strani ponude. Polazi se od uočavanja kritičnih nedostataka lokalne infrastrukture, manjka i/ili nedostatka u svim vrstama inputa (zemlja, sirovine, rad, kapital, socijalni kapital, kulturni kapital i sl.) i poduzimaju se mjere kojima se uklanjaju uska grla i nedostaci. Iskustva ovakve strategije i primjeri dobre

²¹ Socijalne i druge mjere za olakšavanje ili eliminiranje siromaštva, ulaganje u javnu infrastrukturu i programe i projekte povećanja kvalitete života trebaju biti dio posebnog programa društvene i socijalne regeneracije prostora i mjera usmjerenih na retenciju stanovništva pa se ovdje ne razmatraju.

prakse u svijetu sugeriraju da se mora vrlo pažljivo pristupiti investiranju u infrastrukturu jer nije dovoljno bilo kakvo ulaganje. Potrebna su fokusirana ulaganja u onu infrastrukturu koja je kritična.²²

Drugi pristup se temelji na mjerama na strani potražnje. U gotovo svim nerazvijenim lokalnim zajednicama s gospodarstvima koja sporo rastu ili opadaju jedan od uzroka takvog stanja je suviše veliko oslanjanje samo na lokalno tržište odnosno nesposobnost dostizanja velikih tržišta, u ovom slučaju obližnjeg tržišta Zagreba, ali i cjelokupnoga hrvatskog i naročito tržišta Europske unije. Izgradnja potpunog sustava, poticanje umrežavanja lokalnih poslovnih subjekata, politika klasterizacije i poticanja povezivanja s globalnim lancima može u kratkom roku povećati potražnju za robama i uslugama lokalnoga gospodarstva.

Treća skupina mjera može biti usmjerena na stvaranje institucionalnog okvira za poticanje gospodarskog rasta. Kao što je u teorijskom dijelu rada konstatirano, upravo je institucionalna insuficijencija jedna od najvećih prepreka rastu gospodarstava nerazvijenih regija. Mjere kojima se ovaj nedostatak može ukloniti uključuju osnivanje i poticanje aktivnog rada lokalnih poslovnih udruga i udruženja, profesionalnih udruženja, gospodarskih komora, poslovnih mreža, udruženja poslovnih subjekata u najvažnijim djelatnostima. Lokalne vlasti moraju, bez obzira na ograničenja, preuzeti aktivniju lidersku ulogu i stvarati pozitivnu poslovnu i investicijsku klimu te stvarati dobru sliku (image) regije i pojedinačnih, posebno većih gradova.

Sljedeća skupina mjera može biti usmjerena na specifične potrebe malih poduzeća i poslovnih subjekata koji dominiraju u strukturi lokalnoga gospodarstva. U osnovi potrebno je detektirati njihove glavne probleme radi stvaranja uvjeta za bolje financijske rezultate poslovanja i povećanje stope preživljavanja malih poduzeća. Ovo je naročito važno radi stvaranja ozračja koje će ohrabriti što više pojedinaca da se bave poduzetništvom.

Posebna skupina mjera trebala bi se pažljivo usmjeriti na poticanje transformacije lokalnih proizvoda prema proizvodima više faze izrade i stvaranje većeg viška vrijednosti koji ostaje u regiji. Sisačko-moslavačka županija raspolaže preduvjetima za razvoj nekoliko takvih transformacijskih

²² Ovu napomenu smatram veoma važnom zbog puno razloga. Jedan razlog je osobni uvid u projekte koji su bili podloga za definiranje Nacionalnog plana oporavka i otpornosti (NPOO), a koji se odnose na Sisačko-moslavačku županiju. Od gotovo 350 različitih projekata preko 90 posto su projekti različite infrastrukture, ali je mali udio onih projekata koji se odnose na kritičnu infrastrukturu za razvoj gospodarstva.

linija, a posebno se može istaknuti drvo, poljoprivredne sirovine u području stočarstva, proizvodnje mlijeka, voća i povrća, šumskih sirovina i drugo. Umjesto izvoza ovih sirovina u srednjem roku je moguće transformirati ih u sofisticiranije proizvode. Takav pristup primarno zahtijeva veću količinu različitih novih znanja koja se mogu generirati stvaranjem različitih oblika suradnje s hrvatskim sveučilištima i institutima. Moguće je na području regije osnivati različite Centre znanja koji će biti pokretač stvaranja i difuzije novih tehnologija, novih organizacijskih rješenja i rješenja za uključivanje lokalnih poslovnih subjekata u globalne proizvodne i trgovinske lance. U okviru ove strategije mogu se dizajnirati različite mjere koje će pomoći transformaciji nekih zatečenih industrija (i napuštenih pogona i zgrada) u nestajanje u neke nove djelatnosti i industrije, poput osnivanja i razvoja novih postrojenja za proizvodnju obnovljive energije, suvremenih materijala. U ovoj županiji postoje veliki potencijali za različite projekte regeneracije i prenamjene brojnih prostora bivših industrijskih poduzeća. To ne mora uvijek biti nova industrija, može se prema primjerima dobre prakse u europskim državama obaviti prenamjena u nove objekte kulture (muzeji, knjižnice, galerije, kazališta,...), zabave i rekreacije (koncertne dvorane, sportske dvorane, fitnes centri,...) ili ugostiteljstva i turizma (restorani, parkovi industrijske baštine i slično).

Uz navedeno moguće je uspostaviti različite sheme koje će olakšati pristup zajmovima s preferencijalnim uvjetima. Moguće je koristiti i neke moderne inovativne pristupe poput osnivanja investicijskog poduzeća u kojem će manjinske uloge imati lokalne zajednice, banke, domaći i inozemni investitori i slično. Takvo se poduzeće može baviti ulaganjem u različita lokalna mala poduzeća čime se povećava njihova sposobnost osiguravanja financijskih izvora za investicije te stvaraju uvjeti za bolje financijsko poslovanje.

Osim poticanja osnivanja novih poduzeća i osiguravanja veće stope preživljavanja dobro je koristiti i druge oblike inkubiranja poslovnih ideja te pomaganja u razvoju ideja i poslovanja. U tu skupinu mjera pripadaju različiti oblici osiguravanja poslovnog savjetovanja, pružanje informacijskih i drugih poslovnih usluga, mentorstvo za poduzetnike početnike, osnivanje poslovnih klubova, poslovna inkubacija, osnivanje tehnoloških parkova, klastera i slično.

Paralelno s poticajima usmjerenima na postojeće poduzetnike, za puni uspjeh i dugoročno održivu gospodarsku revitalizaciju potrebno je dizaj-

nirati specifične investicijske poticaje, porezne olakšice i niz drugih mjera lokalne i centralne države za privlačenje poduzetnika i poduzeća iz domaćeg i inozemnog okruženja u ovo područje.

Iako neki suvremeni pristupi regionalnoj politici sugeriraju pomak od kompenzacijskih politika odozgo prema politikama povećanja konkurentnosti (Garcilazo et al., 2015), u slučaju Sisačko-moslavačke županije i specifičnosti Republike Hrvatske, takav pristup ne bi mogao biti dovoljno učinkovit iz više razloga. Prvo, jer se u primjeni tih pristupa radi o mjerama tzv. dugog roka na strani ponude. A da bi se zaustavio snažan trend odljeva radnog resursa koji je ušao u kritičnu fazu, potrebni su pristupi koji mogu ostvariti vidljive rezultate u kratkom roku. Drugo, prostor je u zadnjih nekoliko desetljeća dva puta enormno devastiran, u vrijeme Domovinskog rata i u potresu, pa stanovnici i poduzetnici raspolažu iznimno malim količinama kapitala kojeg bi usmjerili na poduzetničke projekte. Ove štete u zadnjim desetljećima nikada nisu kompenzirane ni stanovništvu ni lokalnim poduzetnicima. Treće, gustoća poduzetništva na koje bi se odnosile mjere povećanja konkurentnosti je višestruko manja od prosjeka Republike Hrvatske pa zapravo nema dovoljnog broja poduzetnika čija bi se konkurentnost, pogotovo u kratkom roku, mogla poboljšati. Osim toga, zatečeno poduzetništvo je na vrlo niskoj kvalitativnoj razini, što odražava iznimno nisku poduzetničku kulturu u prostoru, a mjere popravljivanja poduzetničke kulture također mogu donijeti vidljive učinke tek u duljem roku. U ovom prostoru je potrebno prije svega značajno povećati broj poduzetnika, a to znači da se u početnoj fazi moraju koristiti klasične mjere za generiranje novog broja poduzetnika, a tek nakon dostizanja određene razine broja i kvalitete poduzetnika moguće je obaviti tranziciju prema korištenju suvremenijih mjera. U ovom kontekstu valja ponovno podsjetiti da su sve zemlje OECD-a u vrijeme kada su one bile na ovakvoj razini razvijenosti, upravo ovakvim mjerama poticale rast poduzetništva, a mnoge i danas to čine na iste ili slične načine upravo vodeći računa o razvojnim specifičnostima pojedinih svojih regija. I na kraju, ne manje važno, nacionalni konteksti u različitim zemljama se bitno razlikuju. Autonoman razvoj lokalnih zajednica (općina, gradova, županija) u Republici Hrvatskoj limitiran je visokim stupnjem fiskalne i svake druge centralizacije. Približno 90% fiskalnih kapaciteta koncentrirano je u centralnoj državi koja ima nerazmjerno veliku ekonomsku (i političku) moć i ulogu prilikom alokacije javnih sredstava u odnosu na jedinice JLP(R)S. To je posebno velika barijera za razvoj nerazvijenih JLP(R)S koje nemaju vlastitih financijskih i

razvojnih kapaciteta, što je slučaj gotovo svih JLP(R)S u SMŽ.²³ Iz toga proizlazi i obveza centralne države da obavi alokaciju resursa u korist poticanja razvoja manje razvijenih regija jer tih resursa nema u lokalnim zajednicama pa se od njih općenito ne može očekivati brze i velike razvojne iskorake.²⁴

Kada se radi o strategiji privlačenja poduzetnika i poduzeća (egzogeni razvoj), mora se odgovoriti na pitanje što poduzetnicima i poduzećima treba da bi donijeli odluku o dolasku u neku regiju. Sasvim je razumljivo da će poduzeća donijeti odluku o seljenju poslovnih aktivnosti u one prostore i na lokacije u kojima mogu ostvariti veći profit nego što je to slučaj na sadašnjim lokacijama te u prostore koji nude neke rijetke ili jeftinije inpute (sirovine, radnu snagu). Općenito, poduzeća će donositi odluke o seljenju poslovnih aktivnosti tek nakon ispitivanja mogu li na nekoj lokaciji računati na neke od sljedećih čimbenika:

- Znanje o postizanju boljeg poslovnog uspjeha i informacije o tržišnim prilikama i rizicima;
- Kapital za početak poslovanja i rast;
- Pristup tržištima (fizički), ali i postojanje informacijske tehnologije i nepostojanje regulatornih prepreka koje bi taj pristup ograničavale;
- Kvalificirana i produktivna radna snaga;
- Materijalni inputi/zalihe sirovina i sl.;
- Troškovi i cijene lokalnih resursa (plaće, cijene energije, vode i sl.);
- Raspoloživo zemljište (za gradnju proizvodnih hala, distribuciju i maloprodajne aktivnosti);
- Prikladan regulatorni okvir (porezni poticaji, subvencije, standardi, davanje odobrenja i dozvola, ostalo);

²³ Mjere fiskalnog izravnjanja također nisu imale značajnog učinka na ispravljanje uočenih distorzija. Među ostalim, dugoročni negativni razvojni trendovi u potpomognutim područjima impliciraju zaključak o nužnosti reorganizacije sustava usitnjenih JLP(R)S i njihove koncentracije u veće funkcionalne cjeline koje će imati kapacitete za lokalni društveni i gospodarski razvoj.

²⁴ O tome zorno svjedoči činjenica da su u zadnjim desetljećima nešto brži i dinamičniji razvoj ostvarile samo regije Republike Hrvatske u kojima postoje uvjeti za ostvarivanje prirodne rente (Istra, Dalmacija, Jadran) ili rente prostora (Grad Zagreb kao velika metropolska aglomeracija). Sve bivše industrijske regije i ruralni prostori u istom razdoblju su divergirali i nazadovali.

- Dostupnost infrastrukture (meke i čvrste), vode, struje, plina, širokopojasne i optičke veze, dostupnost prometnih sustava;
- Lokalne poticajne mjere;
- Dostupnost poslovnih usluga (opće i specifične za neku industriju ili djelatnost);
- Inovativni kapaciteti (postojanje centara za inovacije, obrazovne institucije, istraživački instituti...);
- Poduzetnička kultura;
- itd.

Analiza zastupljenosti ovih čimbenika i utvrđivanje razine njihove dostupnosti od presudne je važnosti za izradu djelotvorne strategije lokalne zajednice koja se želi osloniti na egzogeni razvoj. Posebno je važno detektirati kritične čimbenike. Većina navedenih čimbenika je u Sisačko-moslavačkoj županiji tek ograničeno zastupljena pa je za osiguravanje dinamičnih promjena i gospodarskog razvoja jako važno predvidjeti strateške aktivnosti usmjerene na jačanje svakog od ovih čimbenika koji predstavljaju elemente lokalnog kapitala i mogu imati privlačnu snagu za poduzeća i poduzetnike iz okruženja. Neki od ovih čimbenika su pod kontrolom lokalne zajednice, neki su pod ograničenom kontrolom, a neki su izvan kontrole pa je važno koordinirano pristupiti njihovom jačanju i u ovom konkretnom slučaju je presudna volja i suradnja lokalnih vlasti i centralne države.

Strategija privlačenja poduzeća i poduzetnika ima brojne prednosti za regije sa slabom i opadajućom ekonomijom. Novi poslovni subjekti unose dodatni kapital i poslovnu kulturu, čime jačaju gospodarsku osnovu, povećavaju integriranost u globalne gospodarske mreže (klastere) i poslovne lance, povećavaju izvoz, unose nova tehnička znanja i tehnologije, pridonose javnom profilu lokalne zajednice i što je u kratkom roku važno, ubrzavaju rast i zaposlenost (izravnu i induciranu u drugim sektorima).

Strategije privlačenja poduzeća koriste različite instrumente i mjere, od različitih tipova subvencija i izravnih poticaja posebno za investicije u nove tehnologije i kvalitetna radna mjesta do ponude zemljišta i poslovnih prostora, zajmova sa subvencioniranom kamatom, nuđenje kvalificirane radne snage i programa za prekvalifikaciju, porezne olakšice i subvencije za neke vrste troškova (porezne olakšice za reinvestiranu dobit i slično). Svaka

od ovih mjera uz pozitivne učinke nosi i rizike. Prilikom izrade strategije potrebno je procijeniti i te rizike te predvidjeti mehanizme umanjenja njihova djelovanja. Radi osiguravanja što boljih učinaka, strategiju privlačenja poduzeća treba kombinirati s politikama koje uzimaju u obzir i druge pokretače lokalnog razvoja, socijalne, političke i naročito institucionalne.

5. ZAKLJUČCI

U radu su analizirani teorijski doprinosi i empirijska iskustva u različitim zemljama koje su bile suočene s potrebom regeneracije regija koje su doživjele prirodnu katastrofu poput razornog potresa i koje su u isto vrijeme bile ekonomski nerazvijene. Sisačko-moslavačka županija analizirana je kao poseban slučaj nerazvijene regije u opadanju koja je u protekla tri desetljeća doživjela više egzogenih šokova (razaranje u Domovinskom ratu, nepovoljna tranzicijska praksa, razorni potresi i pandemija uzrokovana koronavirusom). Posljedica dugotrajnih negativnih razvojnih trendova i serije egzogenih šokova je stalni trend pada broja stanovnika i smanjenje radnog resursa, što je dovelo do gospodarskog i demografskog sloma, što prijeti da se prostor ove regije ubrzo isprazni.

Ako se kao strateški cilj definira zaustavljanje navedenih negativnih gospodarskih i demografskih trendova, zbog katastrofalnih posljedica zatečenog stanja, potrebno je dizajnirati strategiju koja će primarno biti usmjerena na poduzimanje onih mjera koje imaju potencijal ostvarivanja pozitivnih promjena u kratkom roku. Analiza teorijskih pristupa i rezultati empirijskih istraživanja potvrđuju hipotezu da postoji znatna razlika u pristupu razvoju različitih regija te da iste mjere regionalne i lokalne razvojne politike nemaju iste učinke u regijama visoke razvijenosti s visokim stopama rasta i nerazvijenim regijama u nestajanju koje su uz to izložene seriji egzogenih šokova.

To se posebno odnosi na žurnu promjenu demografskih trendova koje nije moguće preokrenuti bez brzih promjena u rastu lokalnoga gospodarstva, rastu zaposlenosti i dohotka. Slijedom navedenih rezultata ovog istraživanja, kao optimalan pristup sugerira se simultano korištenje mjera endogenog i egzogenog razvoja. Mjere koje se moraju dizajnirati nužno uključuju istodobnu aktivnu ulogu lokalnih vlasti i centralne države. Uvažavajući nacionalni kontekst visokog stupnja centralizacije fiskalnih i financijskih

resursa, uloga centralne države mora se kvalitetno koordinirati s mjerama lokalnih vlasti. Osnovni cilj svih mjera mora biti poticanje efikasnijeg korištenja teritorijalnog kapitala radi brzog povećanja poslovne aktivnosti i jačanja tržišne snage i sposobnosti tržišnog natjecanja privatnih poslovnih subjekata, dok se različite razine vlasti pojavljuju u ulozi olakšavanja i poticanja te uklanjanja prepreka rastu.

LITERATURA

- Beer, A. (2009). *The Theory and Practice of Developing Locally*. U J. E. Rowe, *Theories of Local Economic Development: Linking Theory to Practice*. Thousand Oaks: Sage Publications.
- Beer, A., & Clower, T. (2020). *Globalization, Planning and Local Economic Development*. London and New York: Routledge.
- Čavrak, V. (2011). Regionalna politika i regionalne nejednakosti u Hrvatskoj. U Č. (ur.), *Gospodarstvo Hrvatske* (str. 321-348). Zagreb: Politička kultura, nakladno-istraživački zavod.
- Čavrak, V. (2012). Shift-share analiza županija Republike Hrvatske. *Zbornik Ekonomskog fakulteta u Zagrebu*, str. 79-96.
- Čavrak, V. (2014). Utjecaj migracija visokoobrazovanih stručnjaka na razvoj Hrvatske. U T. V. Puljiz, *Migracije i razvoj Hrvatske: Podloga za hrvatsku migracijsku strategiju* (str. 117-129). Zagreb: Croatian Chamber of Economy.
- Čavrak, V. (2020). Makroekonomski aspekti obnove, izravna i neizravna šteta. *Perspektive, 2020, broj 1-2*, str. 23-27.
- DZS. (2011). Popis stanovništva.
- DZS. (razne godine). *Stanovništvo – pregled po županijama*. Zagreb: DZS.
- EU. (2011). *Territorial Agenda of the European Union, Towards an Inclusive, Smart and Sustainable Europe of Diverse Regions*. Godollo, Hungary: EU 2011.hu.
- FINA. (razne godine). Godišnja izvješća o financijskom poslovanju poduzetnika. Zagreb: FINA.
- Garcilazo, E. (2015). The Modern Regional Policy Paradigm: Rationale and Evidence from OECD Countries. *GOT – Geography and Spatial Planning Journal* 7:9-44, str. 9-44.
- Jurlina-Alibegović, D. (2021). Pregled tržišta nekretnina u Republici Hrvatskoj 2020. *Regio-novosti, broj 18*, str. 8-11.
- Jurlina-Alibegović, D. (2021). Porez na dohodak po županijama u 2020. godini. *Regio-novosti, broj 18*, str. 3-4.
- Krugman, P. (1991). *Geography and Trade*. Cambridge, MA: MIT Press.
- Mankiw, G., Romer, D., & Weil, D. (1992). A Contribution to the Empirics of Economic Growth. *The Quarterly Journal of Economics*.

- Mintzberg, H. (1987). The Strategy Concept I: Five Ps for Strategy. *California Management Review*, Vol. 30, Issue 1, str. 11-24.
- Myrdal, G. (1957). *Rich Lands and Poor*. New York: Harper and Row.
- Nujić, A. (1990). Razlike u razvijenosti općina SR Hrvatske. *Ekonomski analitičar*, str. 3-7.
- OECD. (1979). *The Role of Industrial Incentives in Regional Development*. Paris: OECD.
- OECD. (2006). *The New Rural Paradigm: Policies and Governance*. Paris: OECD.
- OECD. (2009). *How Regions Grow: Trends and Analysis*. Paris: OECD.
- OECD. (2010). *Regions Matter*. Paris: OECD.
- OECD. (2012a). *Promoting Growth in All Regions*. Paris: OECD.
- OECD. (2012b). *Growth in All Regions*. Paris: OECD.
- Polese, M. (2010). *The Wealth and Poverty of Regions: Why Cities Matter*. Chicago: Chicago University Press.
- Rodriguez-Pose, A. (2013). Do Institutions Matter for Regional Development? *Regional Studies*, str. 1034-1047.
- Rostow, W. W. (1960). *The Stages of Growth*. Cambridge: Cambridge University Press.
- Solow, R. (1956). A Contribution to the Theory of Economic Growth. *The Quarterly Journal of Economic*, str. 65-94.
- Stimson, R., Stough, R., & Salazar, M. (2009). *Leadership and Institutions in Regional Endogenous Development*. Cheltenham: Edward Elgar.
- Valila, T. (June 2020). Infrastructure and Growth: A Survey of Macro-Econometric Research. *Structural Change and Economic Dynamics*, Vol 53, str. 39-49.
- Wadley, D. (1986). *Restructuring the Regions: Analysis, Policy, Model and Prognosis*. Paris: Development Centre Studies.
- World Bank. (2009). *World Development Report 2009 – Reshaping Economic Geography*. Washington DC: World Bank.

ECONOMIC REVITALIZATION OF THE UNDEVELOPED EARTHQUAKE AFFECTED AREA (THE CASE OF SISAK-MOSLAVINA COUNTY)

Abstract

The devastating earthquake that struck the Sisak-Moslavina County on December 28 and 29, 2020, caused colossal direct and indirect damage to an otherwise extremely underdeveloped area. Reconstruction and economic revitalization of such an area has a number of unknowns and challenges. The low level of economic and social development in combination with demographic erosion indicates poor opportunities to generate autonomous development and the need to take strong exogenous incentives. Given the many specifics of historical development and the current situation in the observed area, it is necessary to analyze the theoretical and empirical experiences of similar areas in other countries to formulate a possible model of local economic development and regional policy. The basic hypothesis is that the observed region is characterized by great specificities, deep underdevelopment and disappearing regions as well as exposure to a series of exogenous shocks (war devastation, transition, pandemic COVID-19 and several devastating earthquakes), all of which requires a specific theoretical and practical approach to formulating strategy and various reconstruction and economic revitalization programs. The paper proposes a strategy of integrated territorial development based on all types of available territorial capital combined with an exogenous and endogenous strategy of local economic development.

Keywords: local economic development, regional development, assisted areas, earthquake.

JEL klasifikacija: O4, P2, E24, E10, E62
Izvorni znanstveni rad

UZROCI EKONOMSKOG ZAOSTAJANJA HRVATSKE¹

Josip Tica^{*}

Viktor Viljevac^{**}

SAŽETAK

Prema dostupnim statističkim podacima Hrvatska je jedna od tranzicijskih zemalja čiji je BDP po glavi stanovnika najviše zaostao u odnosu na vodeće tranzicijske zemlje. Osim sporog rasta BDP-a per capita, demografske promjene, odnosno snažno odseljavanje stanovnika smanjilo je potencijalni BDP s direktnim posljedicama na potencijalnu razinu proračunskih prihoda i potrebne fiskalne prilagodbe koje nam predstoje. U prvom dijelu rada sumirat ćemo nalaze znanstveno utemeljenih nalaza o uzrocima ekonomskog zaostajanja Hrvatske s posebnim naglaskom na aktivnost stanovništva i strukturu gospodarstva, a u drugom dijelu rada pažnja se posvećuje utjecaju demografskih promjena, ali i ostalih čimbenika koji djeluju na kretanje potencijalnog agregatnog BDP-a, kao i implikacijama koje navedeno kretanje ima na očekivanu potencijalnu razinu proračunskih prihoda i očekivane fiskalne prilagodbe.

Ključne riječi: ekonomski rast, tranzicija, početni uvjeti, stopa zaposlenosti, potencijalni BDP, ciklički prilagođeni proračunski saldo.

^{*} Prof. dr. sc. Josip Tica, Ekonomski fakultet Sveučilišta u Zagrebu (e-mail: jtica@efzg.hr).

^{**} Viktor Viljevac, mag. oec., Ekonomski fakultet Sveučilišta u Zagrebu (e-mail: vviljevac@efzg.hr).

¹ Ovaj je rad financirala Hrvatska zaklada za znanost projektom IP-2019-04-4500.

1. UVOD

Gospodarski rast u dugom roku, s naglaskom na rast BDP-a po glavi stanovnika, jedna je od glavnih odrednica kvalitete života u nekoj zemlji. Teorijskih objašnjenja zašto su neke zemlje uspješne, a neke neuspješne postoji mnogo. U kontekstu hrvatskog zaostajanja, postoji čitav niz više ili manje plauzibilnih objašnjenja zašto se Hrvatska ne nalazi među uspješnijim tranzicijskim zemljama. U prvom je dijelu ovog rada dan prikaz hrvatskog zaostajanja i potencijalnih uzroka tog zaostajanja koji se spominju u javnim raspravama i znanstvenoj literaturi. S ciljem da se istraži koja od tih objašnjenja imaju temelje u stvarnosti, dan je prikaz statističkih podataka usko vezanih uz pojedine hipoteze. Analizirani su podaci o povezanosti razine industrijalizacije i razine razvoja u kontekstu deindustrijalizacije, kao i potencijal strukture hrvatskih investicija u osiguravanju više stope gospodarskog rasta. Problemi povezani s hrvatskim tržištem rada analizirani su u kontekstu institucionalnog okruženja, s naglaskom na stavove i vrijednosti stanovništva povezane s aktivacijom na tržištu rada i vjerom u isplativost marljivog, kvalitetnog i poštenog obavljanja posla.

Drugi dio rada produbljuje zaključke vezane uz kretanja na tržištu rada fokusirajući se na to kako su ta kretanja povezana s potencijalnim BDP-om Hrvatske i ciklički prilagođenim, odnosno potencijalnim razinama proračunskih prihoda i rashoda. U okviru metodologije Europske komisije za izračun potencijalnog BDP-a i ciklički prilagođenog proračunskog salda analizirano je kako su se kretanja različitih faktora koji određuju potencijalni BDP odrazila na visinu potencijalne stope rasta hrvatskoga gospodarstva. S obzirom na to da kretanja potencijalnog BDP-a određuju potencijalne prihode i rashode proračuna neke zemlje, analizirano je kako se promjene faktora koji određuju potencijalni BDP odražavaju na dugoročnu održivost hrvatskih javnih financija u kontekstu Pakta o stabilnosti i rastu i budućih fiskalnih prilagodbi.


2. UZROCI EKONOMSKOG ZAOSTAJANJA²

Zaostajanje Hrvatske koje se dogodilo od osamostaljenja do danas je činjenica koju malo tko danas osporava. Više je nego jasno kako je Hrvatska

² Dijelovi ovog poglavlja preuzeti su iz Tica (2021).

jedan od najvećih gubitnika tranzicijskog procesa (Grafikon 1.). Čak i kada apstrahiramo prvu polovinu devedesetih godina, odnosno Domovinski rat, Hrvatska je od pete najrazvijenije zemlje tranzicijskog bloka u 1995. godini, potkraj prošlog desetljeća završila na jedanaestom mjestu u "tablici" najrazvijenijih tranzicijskih zemalja (Grafikon 1.).

**Grafikon 1. BDP po glavi stanovnika u 1995. i 2017. godini
(Njemačka = 100)**



Izvor: World Development Report (2021).

3. UZROCI ZAOSTAJANJA

Kada se nastavno na tu činjenicu raspravlja o uzrocima ekonomskog zaostajanja Hrvatske, često se **špekulira** (namjerno naglašavamo riječ "špekulira") s čitavim nizom potencijalnih uzroka zaostajanja.

Kao potencijalno objašnjenje vrlo često se koristi "kriminalna" privatizacija, a popularan je i strateški odabir razvoja temeljenog na turizmu i poljo-

privredi, odnosno tzv. rentijerski kapitalizam 19. stoljeća baziran isključivo na eksploataciji prirodnih bogatstava promoviran pod sintagmom "plava i zelena Hrvatska". Od događaja iz devedesetih godina često se spominje i šok terapija primijenjena u stabilizacijskom programu te pogrešno odabrana razina apsolutnog tečaja.

Iako se i u početnim godinama tranzicije govorilo o institucionalnom okviru, navedena tema je došla pod povećalo potkraj devedesetih godina. Prema institucionalnom objašnjenju, razorni efekti sporog i netransparentnog pravosuđa, inertne i neefikasne javne administracije, usitnjenih i neodrživih jedinica lokalne samouprave stvorili su uvjete nepovoljne za razvoj poduzetništva, otežavali investiranje, obeshrabrivali uključivanje Hrvatske u svjetske dobavne lance te onemogućili održivu reindustrijalizaciju Hrvatske i razvoj sektora temeljenih na ljudskom kapitalu, društvenom povjerenju, odnosno povjerenju u socijalnu infrastrukturu.

Iz neoliberalnog bazena mjera tu je, naravno, stalna teza o rigidnom tržištu rada koje tobože priječi poslodavce u novom zapošljavanju (iako paralelno imamo manjak radne snage i jedan od najvećih udjela privremenih ugovora o radu), kao i preveliko porezno opterećenje Hrvatske kao tema koja je u posljednjem desetljeću zaokupila pažnju javnosti i koja ponajprije zbog prirode političke ekonomije u Hrvatskoj zaokuplja sve veći medijski prostor. Isto tako, u navedenom kontekstu ističe se i prevelika uloga države u gospodarstvu sa svim distorzijama koje netransparentno javno upravljanje nosi u Hrvatskoj.

U kontekstu ekonomskih znanstvenih istraživanja utemeljenih na dokazima (*evidence based theories*), desetljećima su poznati osnovni postulati koji objašnjavaju ekonomski rast u dugom roku.³ Unutar ekonomske struke postoji snažan konsenzus kako varijaciju u BDP-u per capita među zemljama možemo objasniti pomoću količine fizičkog, ljudskog (obrazovanje) kapitala kojima zemlje raspolažu i efikasnosti u korištenju navedenih dvaju faktora (Mankiew, Romer i Weil, 1992; Dougherty i Jorgensen, 1996; Hall i Jones, 1999).⁴ Akumulacija opreme, strojeva,

³ Tri desetljeća tranzicije neosporno se kvalificira kao dugi rok u ekonomiji i kada uočimo fenomen koji traje toliko dugo, onda je prikladno koristiti adekvatne teorije koje mogu objasniti kretanja promatranih varijabli u dugom roku.

⁴ Neslaganje postoji oko relativne važnosti fizičkog kapitala, ljudskog kapitala i podizanja efikasnosti (Dougherty i Jorgensen, 1996). Npr. Mankiew, Romer i Weil (1992) su procijenili kako 3/4

infrastrukture, zgrada i znanja objašnjava većinu razlika u razvijenosti među zemljama. Isto tako, prema starim (egzogenim) teorijama rasta (Solow, 1956, 1957), ali i novim (endogenim) teorijama rasta (npr. Romer, 1990) jedan od ključnih čimbenika stope rasta BDP-a u dugom roku su inovacije, odnosno implementacija novih ideja, društvenih ili proizvodnih organizacija koje dovode do tzv. tehnoloških promjena, odnosno rasta produktivnosti, i to ne samo rada nego i rasta produktivnosti i ljudskog i fizičkog kapitala (ukupna faktorska produktivnost) (Hall i Jones, 1999).

U kontekstu navedenih teorija objašnjenje dugoročnoga ekonomskog zaostajanja Hrvatske trebalo bi tražiti u čimbenicima koji dovode do veće ili manje akumulacije obrazovanja i fizičkog kapitala unutar jedne populacije, odnosno veće ili manje efikasnosti u korištenju fizičkog kapitala, rada i znanja u gospodarstvu.

Upravo se u tom kontekstu pojavljuje tzv. institucionalna ekonomija (npr. nobelovac Douglas North ili autor knjige "Zašto nacije propadaju" Daron Acemoglu).⁵ Hall i Jones (1999) u svom empirijskom istraživanju o utjecaju institucionalnog okruženja koriste i izraz "socijalna infrastruktura" kao sinonim za institucije. Prema tumačenju institucionalista upravo su **percipirane**⁶ institucije, odnosno "pravila igre" mentalne slike koje

devijacija u BDP-u per capita među zemljama koje nisu izvoznice nafte i koje nisu članice OECD-a možemo objasniti pomoću udjela investicija u BDP-u i prosječnog broja godina provedenog u školovanju po stanovniku. S druge strane, Hall i Jones (1999, str. 10.) u Tablici 1. dekomponiraju BDP po radniku među zemljama i ukazuju kako je prosjek 127 promatranih zemalja na 85% kapitalne opremljenosti koju ima SAD, ali samo na pola razine po razini ljudskog kapitala i efikasnosti implicirajući kako ljudski kapital i efikasnost igraju ključnu ulogu u objašnjavanju zaostajanja zemalja u prosjeku. Prema njima najveći udio varijacije u dohotku po zaposlenom među zemljama objašnjava efikasnost korištenja, a ne akumulacija opipljivih resursa, odnosno socijalna infrastruktura koja motivira populaciju na sinergijsko korištenje znanja i kapitalne opreme.

⁵ Na početku je važno istaknuti kako oko riječi "institucije" postoji velika zablude kada govorimo o ekonomskim teorijama. Naime, kada institucionalisti koriste riječ institucija, oni u biti misle na pravne, moralne i običajne norme koje određuju ponašanje ljudi u nekoj zajednici, a ne na formalne organizacije ili ustanove kao što su npr. pravosudni organi. North npr. koristi "pravila igre" kao sinonim za institucije (North, 1992).

⁶ Važno je naglasiti kako se radi o percipiranim institucijama, zato što percepcija, odnosno mentalne slike oblikuju ponašanje dionika u procesima. Mikroekonomska optimizacija događa se na temelju informacija koje su dostupne i percipirane, a ne nužno stvarne. Međutim, iako percepcija može biti gora ili bolja od stvarnosti, ona će djelujući na ponašanje dionika, imati stvarne posljedice. Npr. *bank run* je tipičan primjer kada čak i slučajno potaknuta panika može postati samoostvarujuća prognoza.

određuju ponašanje stanovnika, a koje rezultiraju većom ili manjom akumulacijom tzv. faktora rasta, odnosno obrazovanja i fizičkog kapitala.

Najlakše je "pravila igre" razumjeti na primjeru. Npr. ako u nekom društvu postoji percepcija kako je za uspjeh u životu važno imati "veze" te kako obrazovanje ne korelira s društvenim statusom i ekonomskim uspjehom u životu, onda će u prosjeku obitelji biti spremne daleko manje novca i vremena uložiti u obrazovanje, a navedeni svjetonazor će preslikavati i na potomke i okruženje. Njihova će percepcija postati samoostvarajuća prognoza. Neovisno o tome je li ta percepcija točna ili netočna, njezina posljedica na akumulaciju ljudskog kapitala bit će negativna i limitirat će razvojne mogućnosti zemlje u dugom roku.

Sličnu institucionalnu analogiju možemo povući i s konceptom pretvorbe/privatizacije iz devedesetih godina. Ako su ključne poruke ekonomske politike "tko je jamio jamio" i "kilo mozga dvije marke", onda se stvara percepcija kako je podobnost ili pripadnost "klijentističkoj kliki", a ne poduzetništvo ključno za uspjeh u društvu. Navedeni sustav vrijednosti posljedično dovodi do smanjene poduzetničke aktivnosti i niže stope investicija u dugom toku, što također smanjuje akumulaciju fizičkog kapitala i dugoročnu stopu rasta.

U konačnici, prema ekonomskoj teoriji, u zemlji ili društvu u kojem promovirate "pravila igre" koja su kompatibilna s podobnošću i umrežavanjem nasuprot stručnosti, radu i poduzetništvu, u dugom roku dobijete nižu akumulaciju kapitala, lošije obrazovanu populaciju i anemičnu poduzetničku aktivnost. Posljedice svega navedenog su, naravno, gospodarska stagnacija ili u najboljem slučaju anemičan rast u kojem zaostajete za drugim zemljama.

Loš institucionalni okvir, odnosno promoviranje poltronstva, podobnosti i veza može imati efekte i na radne napore, a ne samo na akumulaciju obrazovanja i fizičkog kapitala. Npr. ako se stvore "pravila igre" prema kojima zavlada percepcija kako se ne isplati raditi, onda će se enormna količina energije, vremena i novca početi trošiti na pokušaje da što veći broj ljudi izbori neku rentu i izađe iz svijeta rada. Kroz povlaštene mirovine, braniteljski status, status majke odgajateljice, "tuneliranje" novca iz poduzeća u rentijerski ("zimmer frei") sektor itd.

Popularizacija izlaska ljudi iz svijeta rada također u dugom roku djeluje destruktivno na perspektivu rasta zato što sve manji broj ljudi radi i stvara

BDP. Kako se stupanj razvoja mjeri BDP-om po glavi stanovnika, smanjenje aktivnosti radne snage smanjit će BDP, a nazivnik, odnosno broj stanovnika će *ceterus paribus* ostati isti, što će rezultirati padom BDP-a po glavi stanovnika.

Sličnu paralelu se može povući i za sustav inovacija, odnosno poticanje tehnoloških promjena. Baziranje ekonomije na rentijerstvu i naslanjanje privatnog sektora na procese javnih nabava kao dominantan izvor prihoda potiče razvoj poduzetništva u kojem inoviranje nije visoko na listi prioriteta, barem ne ona vrsta inoviranja koja može povećati prosječan BDP po glavi stanovnika. Slično se može konstatirati i za pretvorbu u kojoj je mikroekonomski rast produktivnosti postizan prijevremenim slanjem ljudi u mirovinu, tako da je vrlo često izostajao rast makroekonomske produktivnosti po stanovniku, dok bi rast produktivnosti po radniku bio isključivo lokalna unutar poduzeća.

Osim institucionalnog objašnjenja zaostajanja Hrvatske postoji i teorija "Nizozemske bolesti" prema kojoj snažan rast jednog sektora u zemlji može devastirajuće djelovati na razvoj ostatka zemlje. Još od Copelanda (1991) se zna kako gotovo svu dodanu vrijednost u turizmu "prisvajaju" vlasnici nekretnina, dok ostatku ekonomije preostaju negativne eksternalije u vidu gužve, zagađenja i istiskivanja drugih ekonomskih aktivnosti. Osim navedenih distorzija, razvoj nekretninskog poslovanja naslonjenog na turizam stvara i čitav niz distorzija u političkoj ekonomiji od "poreznih oaza" sve do narušavanja opće konkurentnosti kroz permanentne devijacije na stambenom tržištu i tržištu rada.

4. EMPIRIJSKI DOKAZI


Sve nabrojene teorije se u domaćoj ili znanstvenoj zajednici često nude kao potencijalna objašnjenja toga što se dogodilo u Hrvatskoj i upravo zato se koristi riječ "špekulacija" u početnom odlomku. Važno je imati na umu kako u strogo znanstvenom smislu logičnost objašnjenja ne smijemo poistovjetiti s dokazivanjem. Imati logično objašnjenje zaostajanja neke zemlje je obećavajuće i poželjno, ali samo po sebi ne predstavlja znanstveno utemeljeno objašnjenje. Želimo li formiranje ekonomske politike bazirati na dokazima "*evidence based theories*", onda je važno sva nabrojena teoretska objašnjenja doživjeti kao konkurirajuće ili komplementarne hipoteze i testirati ih na podacima.

Pogledamo li studije koje su utemeljene na ozbiljnim ekonomskim istraživanjima, možemo pronaći čitav niz radova koji nude djeliće mozaika. Ivan Kožić (2019) s Instituta za turizam pronašao je dokaze kako razvoj turizma u lokalnim zajednicama smanjuje motive za obrazovanjem mladih. Recher i Rubil (2020) s Ekonomskog instituta u Zagrebu pronašli su vezu između rasta turističke aktivnosti i porasta kaznenih djela protiv imovine. Mikulić, Vizek, Stojčić, Payne, Čeh-Časni i Barbić (2021) pronašli su vezu između sezonalnosti turizma i dostupnosti stanovanja za lokalno stanovništvo. Svi rezultati u biti ukazuju na opasnosti od baziranja razvoja isključivo na turizmu.

Kada govorimo o utjecaju institucionalnog okvira na nove ideje koje bi trebale povećavati produktivnost gospodarstva, najindikativnije je istraživanje Iootty, Correa, Radas i Škrinjarić (2014) prema kojima u Hrvatskoj "tržište u biti eliminira poduzeća koja su relativno produktivnija". Njihov rezultat u biti implicira kako postoje formalne i/ili neformalne institucije, odnosno "pravila igre" koja otežavaju inovativnim poduzetnicima preživljavanje. To je u biti rezultat koji je suprotan od bilo kakvog uobičajenog očekivanja za tržišno gospodarstvo.

Tica i Viljevac (2020) su u kontekstu dugog roka analizirali faktore ekonomskog rasta u tranzicijskim zemljama od 1990. naovamo. Prema njihovom istraživanju, investicije, početna razina razvoja, stopa zaposlenosti (aktivnost radne snage), politička stabilnosti i udio prerađivačke industrije pokazali su se kao ključne i najrobusnije varijable u objašnjavanju rasta. Navedeni podatak posebno je zanimljiv u kontekstu doktrine deindustrijalizacije koja je u Hrvatskoj dugo vremena bila prihvaćena kao jedna od dogmi tranzicije iako o tome nije bilo dokaza u promatranom uzorku. Tica (2020) npr. pokazuje kako je BDP per capita bio pozitivno koreliran s udjelom industrije u svim novim članicama EU s iznimkom prehrambene i tekstilne industrije (Grafikon 2.).

Grafikon 2. Udio industrije strojeva i vozila, kemijske industrije i ostalih industrija (bez prehrambene, odjevne i tekstilne) u BDP-u u odnosu na BDP per capita u tranzicijskim zemljama




Izvor: World Development Report (2021), Tica (2020).

Kada govorimo o dokazima o utjecaju institucija na ekonomski rast, tu se prije svega makroekonomske institucije koncentriraju na panele s velikim brojem zemalja i dugim serijama podataka gdje se pokušava izmjeriti utjecaj institucija na gospodarstvo. Sala-i-Martin (1997) je u vrlo utjecajnom radu nakon 4 milijuna regresija ukazao kako su s ekonomskim rastom uglavnom korelirane politička stabilnost, vladavina prava, otvorenost, distorzije realnog tečaja (negativna korelacija), investicije u opremu i ostale investicije (većinom nekretninske). Međutim, ono što je važno istaknuti u kontekstu Hrvatske je kako je prema Sala-i-Martinu utjecaj investicija u opremu na ekonomski rast bio pet puta jači od utjecaja ostalih investicija (nekretnine). Navedeni rezultat je posebno interesantan ako imamo u vidu činjenicu kako

je udio ulaganja u postrojenja i opremu u Hrvatskoj manji od 13% ukupnih investicija (Grafikon 3.).

Grafikon 3. Struktura investicija u Hrvatskoj od 2000. do 2017. godine




Izvor: Tica i Šagovac (2019).

Od institucionalnih aproksimatora u sličnim radovima se uvijek ističe vladavina prava, političke slobode i kvaliteta upravljanja. Janine Aron (2000) u pregledu literature u časopisu Svjetske banke ističe kako su kvaliteta i efikasnost u provođenju ugovora, vlasničkih prava i razvoj civilnog društva indikatori koji se ističu u studijama. Dokazi, kao što teorija i predviđa, ponajprije ukazuju kako formalne i neformalne institucije prije svega pospješuju akumulaciju kapitala, a preko njega djeluju na ekonomski rast. Urbano et al. (2019) nude pregled povezanosti između institucija, poduzetništva i ekonomskog rasta. Prema njima su neformalne institucije (kulturne norme, uvjerenja, društvene vrijednosti) bile najvažnije u promicanju poduzetništva i preko poduzetništva i razvoja industrije u poticanju ekonomskog rasta. Direktan utjecaj institucija na rast u Hrvatskoj

istraživali su Buterin, Olgić Draženović i Jakovac (2018) i došli su do sličnih zaključaka. Ekonomske slobode, prava vlasništva, otvorenost i vladavina prava su istaknuti kao najvažnije institucije od formalnih, a autori u tekstu naglašavaju kako ni neformalne institucije ne smiju biti zanemarene. Mačkić (2020) isto tako u empirijskom istraživanju pokazuje kako indikatori "kronizma" i "familizma" statistički značajno i negativno djeluju na izvoz i BDP općenito u Bugarskoj, Rumunjskoj i Hrvatskoj.

Iako je institucionalni okvir jako nezahvalno kvantificirati, postoji čitav niz istraživanja čiji rezultati impliciraju kako je u Hrvatskoj percepcija o "pravilima igre" takva da donosi destruktivni moment u procesu akumuliranja čimbenika rasta. Npr. institucionalni aspekt je praktični alarmirajući ako pogledamo podatke iz Eurobarometra iz travnja 2018. godine pod naslovom *Fairness, inequality and inter-generational mobility* (Eurobarometer 2018). Prema podacima ankete provedene na 28.031 ispitaniku, podaci o neformalnim institucijama za Hrvatsku su poražavajući. Po postotku ispitanika koji se slažu da su političke veze esencijalne ili važne, Hrvatska se nalazi na prvom mjestu u EU. Čak 88% ispitanika smatra da su esencijalne i važne (Grafikon 4.).


Grafikon 4. Odgovori na pitanje koliko su političke veze važne za uspjeh u životu (od vrha prema dnu su odgovori: ne znam, nevažne, važne, esencijalne)



Izvor: Eurobarometer (2018).

Na pitanje o važnosti poznanstava za uspjeh u životu Hrvatska je na četvrtom mjestu iza Bugarske, Mađarske i Cipra s 94% osoba koje misle da su poznanstva esencijalna ili važna.

Grafikon 5. Odgovori na pitanje koliko je poznavanje "pravih" ljudi važno za uspjeh u životu (od vrha prema dnu su odgovori: ne znam, nevažno, važno, esencijalno)




Izvor: Eurobarometer (2018).

Logiku snažne urušenosti socijalne infrastrukture, neformalnih institucija, odnosno općenitog odsustva društvenih vrijednosti prati i odgovor na pitanje koliko je sreća važna za uspjeh u životu. Po odgovoru na to pitanje Hrvatska se nalazi na drugom mjestu, odmah iza Bugarske. Čak 48% ljudi smatra da je esencijalno imati sreće da bi se uspjelo u životu (Grafikon 6.). Indikativno je, naravno, da su Bugarska i Hrvatska paralelno s tim i na začelju EU po razvijenosti.

Nasuprot tome, na pitanje koliko je marljivost važna za uspjeh u životu, Hrvatska je uvjerljivo posljednja po udjelu onih koji marljivost smatraju važnom za uspjeh u životu. Samo 13% ispitanika smatra da je marljivost esencijalna za uspjeh. Osim toga, samo 45% ispitanika u Hrvatskoj ima veći stupanj obrazovanja od majke, a samo 35% je obrazovanije od oca. Za razliku od Hrvatske, na razini EU ispitanici najvažnijim rangiraju dobro zdravlje, zatim obrazovanje i marljivost (Grafikon 7.).

Grafikon 6. Odgovori na pitanje koliko je sreća važna za uspjeh u životu (od vrha prema dnu su odgovori: ne znam, nevažna, važna, esencijalna)


QA2.6 How important do you think each of the following are for getting ahead in life?



Izvor: Eurobarometer (2018).

Grafikon 7. Odgovori na pitanje koliko je marljivost važna za uspjeh u životu (od vrha prema dnu su odgovori: ne znam, nevažna, važna, esencijalna)

QA2.3 How important do you think each of the following are for getting ahead in life?




Izvor: Eurobarometer (2018).

Očigledno je kako su tranzicijski procesi i vrijednosti koje su stvorene u navedenim procesima otežavajuća okolnost za pokretanje modernoga ekonomskog rasta temeljenog na akumulaciji znanja i investiranju u poduzetništvo.

Pogledamo li akumulaciju faktora rasta u Hrvatskoj u odnosu na druge tranzicijske zemlje, ishodi postaju logični. Razina investicija u Hrvatskoj je tijekom tranzicijskog procesa bila ispodprosječna (Grafikon 8.), a imamo li na umu strukturu tih istih investicija (Grafikon 3.), kao i činjenicu kako rezidencijalne investicije pet puta slabije djeluju na rast (Sala-i-Martin, 1997), razvojni rezultati Hrvatske djeluju logično.

Grafikon 8. Udio investicija u BDP-u tranzicijskih zemalja od 1995. do 2017. godine




Izvor: World Development Report (2021).

Ispodprosječna akumulacija fizičkog kapitala i iskrivljena struktura navedenih investicija sigurno je jedan od glavnih čimbenika zaostajanja, međutim istraživanja pokazuju kako je sposobnost nosioca ekonomske politike u povećavanju stope zaposlenosti u grupi tranzicijskih zemalja čak i važniji čimbenik rasta tijekom tranzicije (Tica i Viljevac, 2020). Pogledamo li podatke za rast stope zaposlenosti u Hrvatskoj, razvidno je kako su

očigledno stvorena "pravila igre" koja su omogućila značajnom dijelu radno sposobne populacije izlazak iz svijeta rada. Prema poredbenim podacima, Hrvatska je jedna od rijetkih zemalja u kojoj je stopa zaposlenosti smanjena između 1995. i 2017. godine (Grafikon 9.).

Grafikon 9. Stopa rasta stope zaposlenosti



Izvor: World Development Report (2021).

Ovdje je važno dakle još jednom napomenuti kako rast stope zaposlenosti povećava BDP per capita *ceterus paribus* zato što se BDP per capita računa po stanovniku neovisno o radnom statusu ili dobnoj strukturi, pa povećanje omjera zaposlenih i stanovništva rezultira većom proizvodnjom za dani broj stanovnika.

Tranzicijski proces je očigledno kreirao "pravila igre" prema kojima su investicije bile ispodprosječne, loše strukture, odnosno usmjerene u sektore s ispodprosječnim povratima (nekretnine), a aktivnost radne snage je sustavno bila smanjivana kroz čitav niz institucionalnih rješenja.

Kod akumulacije ljudskog kapitala Hrvatska ne stoji toliko loše, ali treba imati na umu kako akumulacija ljudskog kapitala ima implikacije u kontekstu EU tržišta rada, tako da odluku stanovnika da se školuju ne

trebamo promatrati isključivo u kontekstu koliko su vještine visoko-obrazovanih vrednovane na lokalnom hrvatskom tržištu rada, nego općenito u kontekstu prilika na europskom tržištu rada. Naravno, u tom kontekstu je za očekivati da bi loša "pravila igre", odnosno institucionalni okvir koji ne vrednuje ljudski trud i vještine u jednoj članici EU trebao "glasanjem nogama" biti glavni čimbenik emigracije, odnosno odljeva mozgova, a ne pada u akumulaciji ljudskog kapitala. U tom kontekstu izuzetno su zanimljiva istraživanja koja ukazuju da među suvremenom populacijom koja se iseljava iz Hrvatske glavni motiv nisu ekonomske prilike, već činjenica kako u zemlji nisu institucionalizirane vrijednosti radne etike i poštenje (Jurić, 2017).

U kontekstu teorija rasta, iseljavanje samo po sebi djeluje na rast BDP-a per capita, jer se BDP dijeli s manjim brojem stanovnika. Naravno, pod uvjetom da se nisu odselili oni koji su do trenutka odlaska aktivno sudjelovali u stvaranju tog BDP-a. Međutim, kada govorimo o potencijalnom agregatnom BDP-u (samo BDP-u, bez dijeljenja s brojem stanovnika), na njegovo će kretanje demografske promjene djelovati na suprotan način. U nastavku je prikazano na koji su način demografske promjene povezane s kretanjima hrvatskoga potencijalnog BDP-a i ciklički prilagođenoga proračunskog salda te kakve implikacije ova povezanost ima na vođenje održive fiskalne politike u srednjem roku u kontekstu Pakta o stabilnosti i rastu. Prije toga su definirani i objašnjeni pojmovi ciklički prilagođenog salda i potencijalnog BDP-a te su objašnjene teorijske veze među njima.

5. POTENCIJALNI BDP I CIKLIČKI PRILAGOĐENI PRORAČUNSKI SALDO

Temeljna je ideja Pakta o stabilnosti i rastu (Europska komisija, 2019), sadržana u velikom broju pravila i procedura koje su dio preventivnog i korektivnog dijela Pakta, osigurati zdravu i održivu fiskalnu politiku u zemljama članicama Europske unije. Relativno brojna i kompleksna pravila i procedure posljedica su njihova postupnog razvoja kroz vrijeme i nastojanja da se spriječi pretjerano zaduživanje zemalja članica u srednjem roku, istodobno vodeći računa o tome da je potrebno dopustiti određenu fleksibilnost po pitanju proračunskih deficita u kratkom roku da se omogući protucikličko djelovanje fiskalne politike u situacijama kada se stvarni BDP

neke zemlje nalazi ispod potencijalnog BDP-a, a pogotovo u recesijama kada je jaz dohotka izrazito velik.⁷

Nakon što je nastupila pandemija COVID-19 Europska komisija aktivirala je opću klauzulu o odstupanju Pakta o stabilnosti i rastu, čime je dala dopuštenje zemljama članicama da se zaduže u iznosima koji nikada ne bi bili dopušteni od strane Komisije u stabilnijim vremenima te da iskoriste pozajmljena sredstva za borbu protiv recesije uzrokovane pandemijom i mjerama povezanim s borbom protiv pandemije (Europska komisija, 2020a, Economic Governance Support Unit, 2021). Aktivacija ove klauzule je iznimka od normalnih vremena kada proračunski deficiti kakvi su zabilježeni 2020. neminovno dovode do ulaska u Proceduru prekomjernog proračunskog deficita (Europska komisija, 2019). Istodobno, aktiviranje ove klauzule primjer je situacije u kojoj je Europska komisija ciljano dopustila da se ugrozi srednjoročna stabilnost javnih financija promatrano u kontekstu kriterija iz Maastrichta u svrhu borbe protiv recesije.

Međutim, u jednom će trenutku Komisija deaktivirati klauzulu o odstupanju koja je trenutno na snazi, što znači da će sva pravila iz Pakta o stabilnosti i rastu ponovno biti aktivna, a veličina stvarnog proračunskog salda i ciklički prilagođenog proračunskog salda ponovno će biti pod utjecajem trenutno suspendiranih pravila iz Pakta.

Ciklički prilagođeni proračunski saldo jedna je od glavnih varijabli koje Europska komisija promatra u kontekstu Pakta o stabilnosti i rastu. Kao što sam naziv govori, riječ je o proračunskom saldu prilagođenom za utjecaj poslovnog ciklusa na javne financije, odnosno na stvarni proračunski suficit ili deficit koji neka zemlja ostvaruje. Iako je ovaj pojam apstraktniji od pojma stvarnog proračunskog salda, on igra ključnu ulogu po pitanju osiguravanja srednjoročne stabilnosti javnih financija u zemljama Europske unije, pri čemu se srednjoročna stabilnost odnosi na vremenski horizont od sljedeće tri, ponekad i četiri godine (Sherwood, 2015, Europska komisija, 2019).

⁷ U recesiji je stvarni BDP uvijek ispod potencijalnog BDP-a, što implicira da je zemlji potrebna ekspanzivna fiskalna politika. Stvarni BDP također može biti ispod potencijalnog i kada zemlja nije u recesiji, primjerice u razdoblju kada je stopa rasta pozitivna, ali relativno niska, niža od potencijalne stope rasta te zemlje. I u tom je slučaju prema teorijskom okviru zemlji potrebna fiskalna ekspanzija, ali manjeg obujma.

Glavni razlog zbog kojeg ciklički prilagođeni proračunski saldo pomaže u sprječavanju pretjeranih proračunskih deficita i posljedičnog rasta javnog duga povezan je s definicijom ovog salda.

Ideja iza procjene ciklički prilagođenog salda je da se otkrije koliko bi iznosio stvarni proračunski saldo kada bi se gospodarstvo nalazilo na svom potencijalnom BDP-u, odnosno kakva bi bila fiskalna pozicija zemlje kada bi se uklonio utjecaj ekspanzije ili recesije na proračun. Primjerice, na vrhuncu poslovnog ciklusa je proračunska situacija iznimno dobra u odnosu na situaciju u ostatku ciklusa. Kako je tada zaposlenost relativno visoka u usporedbi s ostatkom ciklusa, porezi i doprinosi prikupljeni na temelju mase plaća zaposlenih su visoki, što znači da su proračunski prihodi veći u usporedbi s ostatkom ciklusa. Slično, relativno visoke dobiti znače i relativno bolje punjenje proračuna u kontekstu poreza na dobit, a relativno velik broj zaposlenih u kombinaciji s rastom plaća znači i veće prihode od PDV-a zbog porasta osobne potrošnje, kao i rast ostalih proračunskih kategorija kao što su prihodi od trošarina. Istodobno su neki rashodi relativno niži jer su, na primjer, izdaci za nezaposlene niski zbog toga što je ciklička nezaposlenost mala. Međutim, ova situacija nije dugoročno održiva. BDP će se u jednom trenutku vratiti na svoju potencijalnu razinu, a gospodarstvo će u jednom razdoblju morati proći i kroz fazu recesije ili barem usporenog rasta. Sve će to dovesti do smanjivanja stvarnog proračunskog salda, o čemu treba unaprijed voditi računa, a ciklički prilagođeni saldo u tome pomaže.

Naravno, mogu se naći empirijske iznimke od ovog teorijskog okvira poslovnog ciklusa i njegova utjecaja na proračun. Na primjer, ako zemlja koja je na vrhuncu poslovnog ciklusa ostvaruje proračunski deficit od 2% BDP-a, njezin deficit i dalje ne premašuje razinu od 3% definiranu kriterijima iz Maastrichta, ali to ne znači da je fiskalna politika te zemlje održiva. U trenutku kada rast uspori i dođe do pada proračunskih prihoda i rasta rashoda zbog smanjenja broja zaposlenih i rasta broja nezaposlenih, ova zemlja će gotovo sigurno bilježiti deficite veće od 3%. Upravo iz tog razloga Europska komisija zadaje članicama dodatne proračunske ciljeve koji se izražavaju u terminima ciklički prilagođenog salda. Primjerice, zemlja koja na vrhuncu poslovnog ciklusa ostvaruje spomenuti deficit od 2% BDP-a bi možda u terminima ciklički prilagođenog salda, odnosno salda koji se dobije kada se iz proračuna makne utjecaj povećanih prihoda i smanjenih rashoda koji se mogu pripisati fazi ekspanzije, ostvarivala deficit od 4% BDP-a. Samim time bi Europska komisija unaprijed mogla upozoriti

zemlju na potencijalnu neodrživost njenih javnih financija i nastojati je pomoću pravila iz Pakta potaknuti i prisiliti na odgovornije vođenje javnih financija (Europska komisija, 2019).

U teoriji, zemlja koja poštuje srednjoročne ciljeve koje joj Komisija propisuje imat će dovoljan fiskalni prostor za protucikličko djelovanje, s naglaskom na izbjegavanje probijanja stvarnog deficita od 3% u fazi recesije. Ovi se ciljevi propisuju u terminima strukturnog salda, koji je jednak ciklički prilagođenom saldu usklađenom za jednokratne efekte i mjere. Primjer jednokratnih mjera u kontekstu Republike Hrvatske je usklađivanje za materijaliziranje jednokratnih obveza po osnovi protestiranih jamstava za Uljanik grupu u 2018., koje je iznosilo 2,5 milijardi kuna, odnosno 0,7% BDP-a (Republika Hrvatska, 2019). Što se tiče konkretnih srednjoročnih ciljeva koje propisuje Komisija, oni nisu određeni samo jednim pravilom već se specifična brojka koja se propisuje nekoj zemlji dobiva primjenom najstrožeg od 3 različita uvjeta. Na primjer, jedan od tih uvjeta je da zemlje koje imaju euro i koje su u tečajnom mehanizmu ERM II ne smiju imati strukturni deficit koji je veći od 1% BDP-a (Economic Governance Support Unit, 2019).

Iako se srednjoročni ciljevi propisuju u terminima strukturnog salda, presudan utjecaj na veličinu strukturnog salda ima veličina ciklički prilagođenog salda na temelju kojeg se strukturni saldo računa. Dakle, iz stvarnog se proračunskog salda računa ciklički prilagođeni saldo, iz kojega se pak računa strukturni saldo. Zemlja koja ne poštuje srednjoročne ciljeve ugrožava dugoročnu stabilnost svojih javnih financija i bit će upozorena od strane Komisije da ukloni svoja odstupanja od srednjoročnih ciljeva, a kontinuirano nepoštivanje tih ciljeva može dovesti do sankcija (Europska komisija, 2019). To implicira da je razumijevanje faktora koji određuju veličinu ciklički prilagođenog salda bitno za odgovorno vođenje fiskalne politike, kao i za poštivanje Pakta o stabilnosti i rastu.

Sukladno aktualnoj metodologiji koju primjenjuje Europska komisija (Mourre, Astarita i Prince, 2014), ciklički prilagođeni proračunski saldo u godini t definira se kao razlika između stvarnog proračunskog salda i njegove cikličke komponente, što se može prikazati jednadžbom 1:

$$CAB_t = \frac{R_t - G_t}{Y_t} - \varepsilon * OG_t \quad (1)$$

Pri čemu je CAB oznaka za ciklički prilagođeni proračunski saldo, R i G predstavljaju stvarne proračunske prihode i rashode, Y je stvarni BDP, ϵ predstavlja koeficijent semi-elastičnosti stvarnog proračunskog salda u odnosu na proizvodni jaz, a OG predstavlja proizvodni ili dohodovni jaz izražen u postotku potencijalnog BDP-a. Slovo t označava razdoblje na koje se odnose spomenute varijable, a u kontekstu metodologije Europske komisije riječ je o godišnjim podacima. Proizvodni jaz za razdoblje t definira se kao razlika između stvarnog i potencijalnog BDP-a u tom razdoblju, nakon čega se ova razlika dijeli s potencijalnim BDP-om u razdoblju t.

Kao što je vidljivo iz jednadžbe 1, stvarni proračunski saldo izražava se u postotku BDP-a. Koeficijent semi-elastičnosti ϵ mjeri utjecaj proizvodnog jaza na stvarni proračunski saldo, odnosno on je mjera elastičnosti proračunskog salda na ciklička gospodarska kretanja. Zanimljivo je da procjene koeficijenata semi-elastičnosti Europska komisija većinom preuzima od OECD-a, a koeficijenti semi-elastičnosti za zemlje članice EU ažuriraju se svakih otprilike deset godina da se izbjegnu prevelike oscilacije u izračunima ciklički prilagođenih salda. To je vidljivo i iz toga što su aktualni koeficijenti semi-elastičnosti koji se koriste u izračunima procijenjeni potkraj 2015., kada su ažurirane semi-elastičnosti procijenjene 2005. (Price, Dang i Botev, 2015). Iako je riječ o jednom jedinom broju koji se procjenjuje za pojedinu zemlju, metodologija za procjenu ovog koeficijenta je relativno složena i sastoji se od velikog broja koraka potrebnih da se on procijeni ekonometrijski. U skladu s time, utjecaje tog koeficijenta na ciklički prilagođeni saldo i posljedične implikacije na fiskalnu politiku nećemo analizirati u ovom radu.

No radi boljeg razumijevanja značenja ovoga koeficijenta dan je primjer kako on utječe na izračun ciklički prilagođenog salda. Price, Dang i Botev (2015) procjenjuju da prosječan koeficijent semi-elastičnosti za zemlje OECD-a iznosi 0,50. Recimo da neka zemlja bilježi stvarni proračunski suficit od 0,5% BDP-a, a da je istodobno njezin stvarni BDP 4% veći od potencijalnog BDP-a, odnosno da proizvodni jaz iznosi 4%. U tom slučaju je ciklička komponenta proračuna jednaka $0,5 \cdot 4\%$, odnosno 2%. U skladu s formulom 1, stvarni proračunski saldo umanjujemo za cikličku komponentu proračuna $0,5\% - 2\% = -1,5\%$. Iako zemlja u stvarnosti bilježi suficit proračuna, izbacivanjem cikličke komponente iz proračuna dolazi se do ciklički prilagođenog deficita od 1,5%. Drugim riječima, da stvarni BDP ove zemlje nije 4% veći od potencijalnog, nego upravo jednak

potencijalnom BDP-u, ta zemlja ne bi bilježila suficit od 0,5%, nego deficit od 1,5% BDP-a. Opet, ovo je bitno u kontekstu srednjoročnog planiranja održive fiskalne politike u okviru poslovnih ciklusa. Pregrijavanje gospodarstva, odnosno pozitivan proizvodni jaz od 4% ne može trajati unedogled, a samim time ni povećani proračunski prihodi i smanjeni proračunski rashodi koji idu u paketu s tim pozitivnim proizvodnim jazom. Pritom treba napomenuti da su procjene proizvodnog jaza neprecizne i sklone velikim revizijama, što predstavlja jedan od ključnih problema povezanih s procjenama ciklički prilagođenog proračunskog salda (Havik et al., 2014).

Ovdje će se dati teorijski okvir i opisati kako i zašto promjene potencijalnog BDP-a utječu na promjene ciklički prilagođenog salda. U oba je slučaja riječ o agregatnim varijablama, odnosno one nisu izražene per capita. Glavni razlog zašto je razumijevanje povezanosti potencijalnog BDP-a neke zemlje i njezina ciklički prilagođenog salda bitno je poboljšanje upravljanja javnim financijama i njihovom održivosti. Kratkoročna kretanja proračunskih prihoda i rashoda, a samim time i suficita ili deficita na kraju godine, pod velikim su utjecajem i cikličkih kretanja u gospodarstvu i diskrecijskih odluka vlasti. Međutim, proračunski prihodi i rashodi su također pod utjecajem i nekih drugih faktora kao što su, primjerice, broj zaposlenih. Ceteris paribus, povećanje zaposlenosti znači veće proračunske prihode, a može značiti i manje proračunske rashode ako su, na primjer, novozaposleni prethodno dobivali neku vrstu naknade od države.

Faktori kao što je potencijalan broj zaposlenih⁸ nalaze se u pozadini potencijalnog BDP-a i oni imaju direktan utjecaj na javne financije neke zemlje. Ciklički prilagođeni saldo je saldo koji neka zemlja bilježi kad je njezin stvarni BDP jednak njezinu potencijalnom BDP-u. Iz toga proizlazi da poboljšanje fiskalne pozicije neke zemlje u terminima ciklički prilagođenog proračunskog salda može proizići iz promjene potencijalnog

⁸ Ovdje je riječ o potencijalnom broju zaposlenih, a ne stvarnom broju zaposlenih, iako se ta dva koncepta u velikom postotku preklapaju. Razlika između potencijalnog i stvarnog broja zaposlenih je u cikličkoj komponenti zaposlenosti, odnosno u broju ljudi čija su radna mjesta vezana uz poslovni ciklus. Recimo, izuzetno dobra turistička sezona u kontekstu velikog proizvodnog jaza može dovesti do zapošljavanja nekih od dugotrajno nezaposlenih ljudi. Međutim, takva radna mjesta su privremenog karaktera i neće postojati u trenutku kada se BDP vrati na svoju potencijalnu razinu. Razlike u faktorima koji određuju stvarni BDP i potencijalni BDP bit će objašnjene u nastavku rada.

BDP-a, odnosno nekog od faktora koji određuju potencijalni BDP. U nastavku je dan prikaz utjecaja potencijalnog BDP-a i faktora koji određuju potencijalni BDP na ciklički prilagođeni proračunski saldo. Iako je ovdje riječ o vezi između potencijalnog BDP-a i ciklički prilagođenog salda, slična veza postoji između stvarnog BDP-a i stvarnog proračunskog salda, o čemu će također biti više riječi u nastavku.

Proizvodni jaz definiran u jednadžbi 1 dan je pomoću jednadžbe 2:

$$OG_t = \frac{Y_t - Y_t^p}{Y_t^p} \quad (2)$$

Pri čemu je Y stvarni, a Y^p s dodatkom gornjeg indeksa p (superscripta) potencijalni BDP, dakako oboje u godini t .

U skladu s jednadžbom 1, ciklički prilagođeni proračunski saldo je funkcija varijabli koje se nalaze u toj jednadžbi, odnosno prema jednadžbi 3:

$$CAB_t = f(R_t, G_t, \varepsilon, Y_t, Y_t^p) \quad (3)$$

Stoga je logičan prvi korak kod analize utjecaja potencijalnog BDP-a na ciklički prilagođeni saldo gledati predznak prve parcijalne derivacije ove funkcije po potencijalnom BDP-u:

$$\frac{\partial CAB_t}{\partial Y_t^p} = \frac{\varepsilon * Y_t}{Y_t^p} > 0 \quad (4)$$

Rast potencijalnog BDP-a *ceterus paribus* dovodi do povećanja (poboljšanja) ciklički prilagođenog salda. S obzirom na to da je prema srednjoročnim ciljevima (Economic Governance Support Unit, 2019) vezanima uz strukturni saldo problematičan previše velik strukturni deficit, porast potencijalnog BDP-a pomaže zemlji ostvariti ciljeve koje joj propisuje Europska komisija. Rast potencijalnog BDP-a povećava ciklički prilagođeni saldo (smanjuje deficit), što 1 za 1 povećava (poboljšava)

strukturni saldo jer se ciklički prilagođeni i strukturni saldo razlikuju samo za utjecaj jednokratnih mjera⁹.

Međutim, jedna mana ovog pristupa je što prva parcijalna derivacija gleda utjecaj potencijalnog BDP-a *ceteris paribus*, odnosno pretpostavlja da promjena potencijalnog BDP-a ne utječe na promjenu ostalih varijabli. I dok je ta pretpostavka opravdana kod utjecaja potencijalnog BDP-a na koeficijent semi-elastičnosti ε koji se iznova procjenjuje relativno rijetko, promjena potencijalnog BDP-a u mnogim slučajevima, ovisno o faktoru u pozadini potencijalnog BDP-a koji uzrokuje promjenu samog potencijalnog BDP-a, direktno utječe i na tri preostale varijable koje određuju ciklički prilagođeni saldo.

Havik et al. (2014) daju pregled aktualne metodologije Europske komisije za procjenu potencijalnog BDP-a, a upravo se potencijalni BDP procijenjen pomoću te metodologije dalje koristi u izračunu ciklički prilagođenog salda. Jedan od faktora koji određuju potencijalni BDP je postojeći kapitalni fond neke zemlje, ali isto tako i iskorištenost kapitala (*capacity utilisation*). Kada do porasta potencijalnog BDP-a dođe zbog porasta kapitalnog fonda, povećat će se potencijalni BDP, ali vrlo vjerojatno i stvarni BDP zbog rasta investicija. Navedeno je posljedica metodologije koju Europska komisija koristi za procjenu potencijalnog BDP-a temeljeno na Cobb-Douglasovoj proizvodnoj funkciji. Porast fizičkog kapitala imat će efekte samo na potencijalni BDP u slučaju ako je porast kapitala praćen padom iskorištenosti kapaciteta (*capacity utilisation*).

Kada porastu stvarni i potencijalni BDP, može se očekivati da će veća stvarna i potencijalna gospodarska aktivnost rezultirati i povećanjem proračunskih prihoda i potencijalnim smanjenjem proračunskih rashoda, ovisno o konkretnoj primjeni povećanog kapitalnog fonda. U tom slučaju će veza između potencijalnog BDP-a i ciklički prilagođenog salda biti kompleksnija od jednostavnoga gledanja prve parcijalne derivacije.

Iako postoji nekoliko različitih kanala utjecaja potencijalnog BDP-a na ciklički prilagođeni saldo ovisno o tome koji se faktor u pozadini potencijalnog BDP-a mijenja, za jednostavnu ocjenu predznaka utjecaja potencijalnog BDP-a na ciklički prilagođeni saldo nije nužno raščlaniti sve

⁹ U teoriji, moguće je da bi rast potencijalnog BDP-a doveo do promjene veličine jednokratnih mjera pa ta veza ne bi bila 1 za 1, međutim za očekivati je da je ovaj utjecaj malen i zanemariv.

te kanale utjecaja da bi se zaključilo je li utjecaj pozitivan ili negativan. Porast potencijalnog BDP-a nužno će dovesti do porasta (poboljšanja) ciklički prilagođenog salda, što je jasno iz prikaza faktora koji određuju potencijalni BDP danih u jednadžbi 5. Drugim riječima, ako neki faktor u pozadini potencijalnog BDP-a svojom promjenom poveća potencijalni BDP, to povećanje potencijalnog BDP-a gotovo uvijek¹⁰ dovodi i do porasta ciklički prilagođenog salda, što je dobro za fiskalnu poziciju zemlje u kontekstu Pakta o stabilnosti i rastu. Havik et al. (2014) modeliraju potencijalni BDP pomoću Cobb-Douglasove proizvodne funkcije čiji je opći oblik dan u jednadžbi 5:

$$Y = f(L, K, TFP) \quad (5)$$

Pri čemu L označava potencijalnu razinu rada, K potencijalnu razinu kapitala, a TFP potencijalnu razinu ukupne faktorske produktivnosti. Ovdje je važno napomenuti kako će se potencijalna razina rada razlikovati od stvarne u kontekstu Phillipsove krivulje za plaće (*Wage Phillips curve*), potencijalna razina kapitala razlikovat će se od stvarne za iskorištenost kapaciteta (*capacity utilisation*), razina potencijalne ukupne faktorske produktivnosti (TFP) razlikovat će se od stvarne za cikličnu komponentu tehnologije. Promjene potencijalne razine kapitala, rada ili produktivnosti djelovat će na potencijalni BDP, a odstupanja nezaposlenosti, iskorištenosti kapaciteta, kao i stacionarne fluktuacije produktivnosti bit će rezultat odstupanja stvarnog od potencijalnog BDP-a. Riječ potencijalno i u ovom kontekstu označava vrijednost pojedine varijable kad se iz nje ukloni utjecaj poslovnog ciklusa.¹¹

¹⁰ U teoriji se može konstruirati primjer u sklopu kojeg porast potencijalnog BDP-a dovodi do smanjivanja ciklički prilagođenog suficita, ali nikada i do povećanja ciklički prilagođenog deficita. Ako promjena nekog od faktora u pozadini potencijalnog BDP-a istodobno poveća i stvarni i potencijalni BDP za isti postotak, proizvodni jaz ostaje nepromijenjen. U slučaju da ta promjena, što je iznimno malo vjerojatno, nema nikakvog utjecaja na proračunske prihode i rashode, efekt nazivnika doveo bi do smanjenja udjela stvarnog proračunskog suficita u BDP-u i pada ciklički prilagođenog suficita, pod pretpostavkom da zemlja ostvaruje suficit. Međutim, iako je ova iznimka u teoriji moguća, u praksi je malo vjerojatna i za potrebe daljnje analize ju se može ignorirati.

¹¹ Sama metodologija uklanjanja cikličke komponente iz rada i TFP-a je relativno složena, no nema utjecaja na smjer veze između potencijalne razine tih faktora i ciklički prilagođenog salda te stoga neće biti objašnjena unutar ovog rada.

Kao što je uobičajena praksa u sklopu računovodstva rasta, TFP predstavlja rezidual, odnosno onaj dio promjena u potencijalnom BDP-u koji se ne može objasniti promjenama potencijalnog rada i kapitala. Iz navedene je proizvodne funkcije jasno da porast potencijalne vrijednosti svake od te tri varijable povećava potencijalni BDP, što pak povećava (poboljšava) ciklički prilagođeni saldo i pomaže fiskalnoj poziciji zemlje i u kontekstu pravila iz Pakta o stabilnosti i rastu, ali prije svega u kontekstu održivosti fiskalne politike, što i je glavni cilj Pakta. Svaka politika koja povećava ukupnu potencijalnu razinu rada, mjereno ukupnim potencijalnim brojem odrađenih radnih sati unutar godine dana, potencijalnu vrijednost kapitalnog fonda zemlje ili potencijalnu razinu ukupne faktorske produktivnosti stoga ima direktan utjecaj na povećanje (poboljšanje) ciklički prilagođenog salda.

Procjena potencijalnog BDP-a pomoću ukratko opisane Cobb-Douglasove proizvodne funkcije omogućuje i procjenu potencijalne stope rasta BDP-a za bilo koju zemlju, pa tako i za Hrvatsku. Potencijalna stopa rasta predstavlja dugoročno održivo stopu rasta BDP-a, pri čemu se izraz "dugoročno održiva" odnosi na stabilnu inflaciju, odnosno tendenciju da je promjena cijena iz godine u godinu stabilna, jednaka, odnosno da ta promjena cijena niti ubrzava niti usporava. To je najjednostavnije promatrati u kontekstu cilja Europske središnje banke o inflaciji ispod, ali blizu 2%. Uz procjenu potencijalne stope rasta, moguće je i raščlaniti doprinose toj potencijalnoj stopi rasta od strane tri navedena proizvodna faktora, potencijalnog rada, potencijalnog kapitala i potencijalne ukupne faktorske produktivnosti. U sljedećoj su tablici prikazane procjene ovih varijabli za Hrvatsku dane od strane Europske komisije u sklopu posljednjeg objavljenog Izvješća za Hrvatsku iz 2020.

Tablica 1. Potencijalna stopa rasta i doprinosi potencijalnom rastu za Republiku Hrvatsku, razdoblje 2004. – 2019., procjene Europske komisije, postotci

	2004. – 2007.	2008. – 2012.	2013. – 2016.	2017.	2018.	2019.
Potencijalni rast (godišnja promjena)	3,0	0,1	0,7	1,3	1,7	2,1
Doprinos rastu potencijalnog BDP-a:						
a) Ukupni rad (u satima) (godišnja promjena)	0,5	-0,5	-0,6	-0,5	-0,2	0,1
b) Akumulacija kapitala (godišnja promjena)	1,9	1,1	0,6	0,7	0,8	1,0
c) Ukupna faktorska produktivnost (godišnja promjena)	0,6	-0,6	0,7	1,1	1,1	1,0

Izvor: Europska komisija, Izvješće za Hrvatsku 2020. (2020b).

Tablica se interpretira na način da se potencijalni rast prikazan u drugom retku može raščlaniti na zbroj doprinosa potencijalnog rada, potencijalnog kapitala i potencijalne ukupne faktorske produktivnosti. Iz navedene je tablice vidljivo da Europska komisija smatra da je glavna kočnica većem rastu BDP-a Hrvatske bilo upravo tržište rada. U razdoblju od 2004. do 2019., prosječan doprinos ukupnoga potencijalnog broja sati rada potencijalnom rastu bio je pozitivan samo u razdoblju od 2004. do 2007., promatrano kao prosjek tog razdoblja. Od 2008. do 2018. potencijalni rad je kontinuirano smanjivao potencijalnu stopu rasta hrvatskoga gospodarstva i pridonosio tome da je njezina ukupna vrijednost bila relativno niska. Tek je 2019. doprinos rada postao blago pozitivan. Ovo je u skladu s povijesnim događanjima – recesija koja je započela potkraj 2008. i oporavak BDP-a koji je u pravom smislu započeo tek potkraj 2014. rezultirali su višegodišnjim negativnim kretanjima na tržištu rada, odnosno padom zaposlenosti i rastom nezaposlenosti. I dok je gospodarski oporavak koji je

uslijedio zasigurno pridonio poboljšanju kretanja u potencijalnom radu, ulazak u Europsku uniju 2013. i olakšan pristup tržištu rada EU uveo je u priču dodatni faktor koji je negativno djelovao na potencijalni rad, emigraciju. Emigriralo je i stanovništvo koje je bilo u kategoriji "Izvan radne snage", ali i nezaposleni i zaposleni, pri čemu je od te tri kategorije emigracija onih koji su već imali posao najviše naštetila potencijalnom radu.

Treba napomenuti da to ne znači da nije potrebno povećavati i potencijalni kapital i potencijalnu ukupnu faktorsku produktivnost u svrhu povećanja potencijalne stope rasta, no potencijalni rad je uvjerljivo glavni uzrok relativno niske potencijalne stope rasta hrvatskoga gospodarstva u promatranom razdoblju. Kao što je prethodno objašnjeno, ova niska potencijalna stopa rasta kojoj je višegodišnji uteg bilo hrvatsko tržište rada ima direktan utjecaj i na javne financije, odnosno smanjenje ciklički prilagođenog proračunskog salda. Negativna su kretanja na tržištu rada prije svega oštetila prihodovnu stranu proračuna u smislu propuštenog prikupljanja poreznih prihoda povezanih s relativno niskim brojem zaposlenih, što vrijedi ako govorimo i o ciklički prilagođenim proračunskim prihodima (potencijalnim prihodima) i o stvarnim proračunskim prihodima zbog velikog preklapanja između ta dva koncepta. Stoga je za dugoročnu održivost javnih financija potrebno voditi računa i o kombinaciji demografskih kretanja i trendova na tržištu rada jer je upravo rad jedan od temeljnih faktora koji određuju veličinu potencijalnog BDP-a, a samim time i ciklički prilagođenog proračuna, a negativna su kretanja ovog faktora u razdoblju od 2008. do 2018. imala negativan utjecaj na javne financije i proračunski saldo, bilo u stvarnim bilo u ciklički prilagođenim terminima.

6. ZAKLJUČAK

U ovom su radu prikazana tri moguća objašnjenja uzroka hrvatskoga ekonomskog zaostajanja. Prvo, s iznimkom tekstilne i prerađivačke industrije, BDP per capita je u svim novim članicama EU pozitivno koreliran s udjelom industrije u BDP-u, što baca sumnju na doktrinu deindustrijalizacije koja je dugo vremena bila prihvaćena kao sastavni dio procesa tranzicije. Drugo, struktura hrvatskih investicija može se okarakterizirati kao relativno neproduktivna zbog visokog postotka ulaganja u nekretnine i niskog postotka ulaganja u postrojenja i opremu, uzevši u obzir da je utjecaj ulaganja u postrojenja i opremu na gospodarski rast višestruko veći od utjecaja ulaganja u nekretnine. To je posebno zanimljivo

i u kontekstu značaja turizma za hrvatsko gospodarstvo, odnosno velikog oslanjanja na prihode od iznajmljivanja nekretnina zbog domaćih znanstvenih istraživanja koja upućuju na razne probleme povezane s pretjeranim oslanjanjem na turizam.

Treće, postoji čitav niz problema povezanih s hrvatskim tržištem rada, koje je prema metodologiji Europske komisije za procjenu potencijalnog BDP-a bilo glavna kočnica gospodarskog rasta u 21. stoljeću. Stavovi, uvjerenja i način razmišljanja stanovništva se u prosjeku (ovdje nipošto nije riječ o poopćavanju na cijelo stanovništvo, već o ponderiranom prosjeku različitih stavova) mogu okarakterizirati relativno lošima (u usporedbi s ostalim zemljama EU) u kontekstu aktivacije na tržištu rada i marljivog i poštenog obavljanja posla. Pritom treba naglasiti da to nije jedino objašnjenje kao ni jedini faktor koji je rezultirao relativno nepovoljnim ishodima na tržištu rada. Nepovoljna kretanja na tržištu rada rezultirala su niskom stopom rasta potencijalnog BDP-a i posljedičnim negativnim utjecajem na potencijalne prihode i potencijalne rashode hrvatskog proračuna putem različitih kanala preko kojih potencijalni BDP djeluje na potencijalne prihode i rashode, a samim time i na ciklički prilagođeni proračunski saldo. U skladu s time, pitanja dugoročne održivosti javnih financija moraju voditi računa i o kretanju faktora koji su u pozadini potencijalnog BDP-a, poglavito kretanjima na tržištu rada.

LITERATURA

Acemoglu, D. i Robinson, J. A. (2012). *Why Nations Fail: The Origins of Power, Prosperity and Poverty* (1st). 1st ed. New York: Crown, 529.

Aron, J. (2000). "Growth and Institutions: A Review of the Evidence." *The World Bank Research Observer*, Vol. 15, No. 1, pp. 99-135. JSTOR, www.jstor.org/stable/3986503. Accessed 15 June 2021.

Buterin, V., Olgić Draženović, B. i Jakovac, P. (2018). Institucije kao determinanta ekonomskog rasta – primjer Hrvatske i odabranih članica EU-a. *Zbornik Veleučilišta u Rijeci / Journal of the Polytechnic of Rijeka*, VI (1), 217-234.

Copeland, B. R. (1991). *Tourism, Welfare and De-Industrialization in a Small Open Economy*, *Economica*, New Series, Vol. 58, No. 232, p. 515-529.

Dougherty, C. i Jorgenson, D. W. (1996). International Comparisons of the Sources of Economic Growth. *The American Economic Review*, 86(2), 25-29.

Economic Governance Support Unit (2021). *Implementation of the Stability and Growth Pact under Pandemic Times*, Directorate-General for Internal Policies, PE 659.618 – March 2021

Economic Governance Support Unit (2019). *An Overview of the Stability and Growth Pact – September 2019*, Directorate-General for Internal Policies, PE 528.745 – September 2019

Eurobarometer (2018). *Fairness, Inequality and Inter-Generational Mobility*, Dostupno na: <https://europa.eu/eurobarometer/surveys/detail/2166>, pristupano 8.9.2021.

Europska komisija (2019). *Vade Mecum on the Stability & Growth Pact*, 2019 Edition.

Europska komisija (2020a). *Komunikacija komisije Vijeću o aktivaciji opće klauzule o odstupanju Pakta o stabilnosti i rastu*, Bruxelles, 20.3.2020.

Europska komisija (2020b). *Izvješće za Hrvatsku 2020., Europski semestar 2020.: ocjena napretka u provedbi strukturnih reformi te sprječavanju i uklanjanju makroekonomskih neravnoteža i rezultati detaljnih preispitivanja u skladu s Uredbom (EU) br. 1176/2011*, Bruxelles, 26.2.2020., SWD(2020) 510 final

Hall, R. E. i Jones, C. I. (1999). "Why do Some Countries Produce So Much More Output Per Worker than Others?," *The Quarterly Journal of Economics*, Oxford University Press, Vol. 114(1), pages 83-116.

Havik, K., Mc Morrow, K., Orlandi, F., Planas, C., Raciborski, R., Roeger, W., Rossi, A., Thum-Thysen, A. i Vandermeulen, V. (2014). *The Production Function Methodology for Calculating Potential Growth Rates & Output Gaps*, European Economy – Economic Papers 2008 – 2015 535, Directorate General Economic and Financial Affairs (DG ECFIN), European Commission.

Iooty, M., Correa, P., Radas, S. i Skrinjaric, B. (2014). *Stylized Facts on Productivity Growth: Evidence from Firm-level Data in Croatia*. Policy Research Working Paper; No. 6990. World Bank Group, Washington, DC. © World Bank. <https://openknowledge.worldbank.org/handle/10986/19387> License: CC BY 3.0 IGO.

Jurić, T. (2017). *Suvremeno iseljavanje Hrvata u Njemačku: karakteristike i motivi, Migracijske i etniške teme*, 33, 3, 337-371., Institut za migracije i narodnosti.

Kozić, I. (2019). *Can Tourism Development Induce Deterioration of Human Capital?* *Annals of Tourism Research*, Vol. 77, str. 168-170.

Mačkić, V. (2020). *Balkanska bolest: doprinos raspravi o političkoj ekonomiji hrvatskog modela kapitalizma*. U: *Devedesete. Kratki rezovi*. Obad, Orlanda; Bagarić, Petar (ur.). Zagreb: IEF i Jesenski i Turk, str. 377-409.

Mankiw, N. G., Romer, D. i Weil, D. N. (1992). "A Contribution to the Empirics of Economic Growth," *The Quarterly Journal of Economics*, Oxford University Press, Vol. 107(2), pages 407-437.

Mourre, G., Astarita, C. and Princen, S. (2014). "Adjusting the Budget Balance for the Business Cycle: The EU Methodology", *European Economy, Economic Papers*, No. 536, European Commission.

North, D. C. (1992). *Institutions, Ideology, and Economic Performance*. *Cato Journal*, 11(3), 477-488.

Price, R., Dang, T. i Botev, J. (2015). *Adjusting Fiscal Balances for the Business Cycle: New Tax and Expenditure Elasticity Estimates for OECD Countries*. OECD Economics Department Working Papers, No. 1275, OECD Publishing, Paris

Recher, V. i Rubil, I. (2020). More Tourism, More Crime: Evidence from Croatia. *Soc Indic Res* 147, 651-675.

Republika Hrvatska (2019). Program konvergencije Republike Hrvatske za razdoblje 2019. – 2022., dostupno na: <https://vlada.gov.hr/UserDocsImages/Vijesti/2019/04%20Travanj/30%20travnja/Program%20konvergencije%202019-2022/Program%20konvergencije%20Republike%20Hrvatske%20za%20razdoblje%202019.%20-%202022..pdf> (pristupano 1. 9. 2021.)

Romer, P. M. (1990). "Endogenous Technological Change." *Journal of Political Economy*, Vol. 98, No. 5, pp. S71-S102. JSTOR, www.jstor.org/stable/2937632. Accessed 17 June 2021.

Sherwood, M. (2015). Medium-Term Budgetary Frameworks in the EU Member States, *European Economy Discussion Paper* 021, European Commission.

Solow, R. M. (1956). "A Contribution to the Theory of Economic Growth." *The Quarterly Journal of Economics*, Vol. 70, No. 1, pp. 65–94. JSTOR, www.jstor.org/stable/1884513.

Solow, R. M. (1957). "Technical Change and the Aggregate Production Function." *The Review of Economics and Statistics*, Vol. 39, No. 3, pp. 312-320. JSTOR, www.jstor.org/stable/1926047.

Tica, J. i Viljevac, V. (2020). Thirty Years After: Economic Growth in Transition Countries, No 2005, EFZG Working Papers Series, Faculty of Economics and Business, University of Zagreb

Tica, J. (2020). "Agnostički pogled na 30 godina tranzicije", *Zbornik Ekonomskog fakulteta u Zagrebu*, Vol. 18, No. 1.

Tica, J. i Šagovac, M. (2019). Analiza dinamike i strukture investicija nefinancijskih poduzeća u Republici Hrvatskoj, *Zbornik radova 27. tradicionalnog savjetovanja Ekonomska politika Hrvatske u 2020. godini*, Opatija, str. 42-64.

Tica, J. (2021). Zašto Hrvatska ekonomski zaostaje – među najvećim smo gubitnicima tranzicijskog procesa, *Perspektive*, godina 11, broj 1-2.

Urbano, D., Aparicio, S. i Audretsch, D. (2019). Twenty-Five Years of Research on Institutions, Entrepreneurship, and Economic Growth: What

Has Been Learned?. Small Bus Econ 53, 21-49. <https://doi.org/10.1007/s11187-018-0038-0>

Xavier X. Sala-i-Martin (1997). "I Just Ran Four Million Regressions," NBER Working Papers 6252, National Bureau of Economic Research, Inc.

DETERMINANTS OF CROATIA'S ECONOMIC DIVERGENCE

Abstract

According to the available data, Croatia is one of the transition countries whose GDP per capita figures are lagging behind the leading transition countries the most. In addition to the slow GDP per capita growth, demographic changes, mainly high emigration flows, decreased the potential GDP and had a direct negative impact on the potential level of budget revenues and the size of the fiscal adjustment needed in the future. In the first part of the paper, we will summarize the findings of scientific literature on the main reasons why Croatia is lagging behind its peers in terms of economic development, with a focus on the level of economic activity of the population and the structure of the economy. The second part of the paper will focus on the impact of demographic changes and changes in other factors which determine the movement of the potential GDP, as well as the implications of these changes on potential government revenues and budget balance.

Keywords: *economic growth, transition, initial conditions, employment rate, potential GDP, cyclically adjusted budget balance.*

JEL klasifikacija: A11, A22, A23

Prethodno priopćenje

ZNANSTVENI REZULTATI I SURADNJA AUTORA S EKONOMSKIH FAKULTETA U OSIJEKU, RIJECI, SPLITU I ZAGREBU

Domagoj Sajter *

SAŽETAK

Svrha ovoga rada je prikupiti i analizirati podatke o nastavnicima s ekonomskih fakulteta u Osijeku, Rijeci, Splitu i Zagrebu s obzirom na njihov znanstveni utjecaj i suradnju pri objavljivanju radova. Izvršena je analiza scijentometrije (citati, h-indeksi) i koautorstava radova. Podaci su prikupljeni sa servisa Google Scholar, Web of Science, Scopus i Crosbi korištenjem specijaliziranih, u ovu svrhu razvijenih pretraživača ("botova").

Zagrebački Ekonomski fakultet zapošljava pojedine nastavnike koji iskazuju najviše scijentometrijske pokazatelje u Hrvatskoj, ali u prosjeku (mjereno medijanom) ipak je na drugom mjestu, iza splitskog Ekonomskog fakulteta. Osječki i riječki ekonomski fakulteti izmjenjuju se na trećem i četvrtom mjestu. Najveći dio promatranih radova ima dva ili tri autora, a vrlo malo ih ima četiri ili više. Navedeno je posljedica regulative, a citiranost nije korelirana s brojem autora. Rezultati su važni za procjenu znanstvenog djelovanja i napredovanja, te za iniciranje diskusije o svrhovitosti i realnosti vrednovanja koautorstava u Hrvatskoj.

* Prof. dr. sc. Domagoj Sajter, Ekonomski fakultet Sveučilišta u Osijeku (e-mail: sajter@efos.hr).

Ključne riječi: ekonomisti, Ekonomski fakultet, scijentometrija, h-indeks, citati.

1. UVOD

Znanstvena relevantnost visokoškolskih predavača delikatna je tema koja zahtijeva obazriv pristup iz više razloga. Visokoobrazovani akademski građani s javnih sveučilišta najveći dio svojih primanja ostvaruju iz državnog proračuna, te stoga imaju svojevrstu dužnost opravdati transfer javnih sredstava i za njih podnijeti račun u formi rezultata svoga djelovanja, a rad sveučilišnih nastavnika obuhvaća tri područja: znanstveno, nastavno i javno (Blau, 1996; Boyer, 1997). Pojedinač rijetko briljira u svima trima, što je razumljivo; nerealno je očekivati visoku talentiranost u svakom od spomenutih područja djelovanja.

U ovom se radu nastoji bar približno kvantificirati jedno od ovih područja: znanstveni utjecaj i doseg, te se pokušava opisati suradnja nastavnika s najvećih hrvatskih ekonomskih fakulteta: osječkog, riječkog, splitskog i zagrebačkog, kao i međupovezanost citiranosti nastavnika i njihove suradnje pri objavljivanju radova. Znanstveni utjecaj uobičajeno se mjeri brojem citata i h-indeksom, što proučava scijentometrija kao "*grana informacijske znanosti koja se bavi primjenom bibliometrije na proučavanje širenja znanstvenih ideja; bibliometrijska analiza znanosti*" (Oxford Lexico, 2021). Povezivanje nastavnika u autorske skupine može utjecati na scijentometrijske pokazatelje, što se (među ostalim) ovim radom želi ispitati. Valja istaknuti da cilj znanstvenog rada nije produkcija citata, ali citati – koliko god bili manjkavi kao mjerilo znanstvenog djelovanja, te podložni manipulacijama (Bartneck & Kokkermans, 2011; Fong & Wilhite, 2017) – ipak ocjenjuju odjek rada znanstvenika; poražavajući su slučajevi u kojima pojedinci tijekom višedesetljetnog radnog vijeka nisu ni na koga utjecali, nitko ih nije referirao, niti je ikad itko aktivno popratio njihove radove, pa makar i kritikom. Stoga, visoko citirana osoba ne mora nužno biti i vrhunski znanstvenik, ali osoba s dužim radnim stažem bez ijednoga citata u svojoj karijeri valja preispitati svoj rad.

Polazišna točka ovoga rada jest činjenica da domaći pozitivni propisi normiraju svojevrzni matematički paradoks po kojemu je sto podijeljeno na tri i dalje sto: "*udio doprinosa pojedinog autora u objavljenim znanstvenim radovima s više od jednog autora vrednuje se kao jedan rad ako rad*

potpisuju do tri autora" (odjeljak 4., članak 17., stavak 12. Pravilnika o uvjetima za izbor u znanstvena zvanja, Narodne novine, br. 28/17, 72/19 i 21/21). Iz ovoga proizlazi da su tri koautora zajedno svaki za sebe stopostotni tvorci jednoga rada, potpuno jednakomjerno kao što je i jedan autor sam stopostotni tvorac jednoga rada, te je stoga interesantno proučiti znanstvena koautorstva s domaćih ekonomskih fakulteta. U tu svrhu preuzeta je baza svih radova iz Hrvatske znanstvene bibliografije (Crosbi; www.bib.irb.hr) koji su pripisani četirima navedenim ekonomskim fakultetima (Osijek, Rijeka, Split, Zagreb), te je učinjena analiza suradnje autora i korelacije citiranosti autora s koautorstvima.

Kao takav, ovaj je rad specifična ekstenzija i ažuriranje prethodnoga istraživanja (Sajter, 2021) na temelju osvježene i proširene scijentometrijske baze podataka, te Crosbi baze; obje formirane i povezane isključivo u svrhu izrade ovoga rada.

U postojećoj literaturi široko su istraživane mreže suradnje (engl. "collaboration networks") među znanstvenicima, odnosno struktura njihovih društvenih mreža, ali ondje nisu bili uključeni subjekti iz Hrvatske, odnosno iz društvenih znanosti. Zaključeno je kako znanstvena zajednica ima svoj "mali svijet" i da su mreže visoko koncentrirane (Newman, 2001). U području psihologije istraženo je pedeset članaka koje je napisao pojedinac, pedeset napisanih u parovima i pedeset napisanih od tri ili više koautora u tri promatrana časopisa (Hartley, 2003), no ondje je promatrano koliko autori zahvaljuju drugima na pomoći pri izradi rada (engl. "acknowledgements"), što u ovom članku nije slučaj. S druge strane, u području ekonomije analizirano je 300 radova objavljenih u 44 različita časopisa s citatima u rasponu od 588 do 3816, no s fokusom na rang časopisa u odnosu na citiranost pojedinačnih radova u tim časopisima (Moosa, 2017).

U domaćem okruženju istražen je časopis *Ekonomski pregled* za razdoblje 1980. – 1990. (11 godina), gdje su obuhvaćena 62 numerirana sveska u kojima je analiziran sadržaj svakog pojedinog sveska (Žugaj et al., 1993). No osim toga uz najbolju volju nisu pronađeni drugi radovi koji bi sustavno analizirali citiranost najznačajnijih domaćih ekonomista, njihovu suradnju pri objavljivanju radova, i međupovezanost citiranosti i suradnje. U tom prostoru ovaj rad pokušava dati svoj doprinos.

Nakon ovoga uvoda i kraćeg pregleda (ne)postojećih prethodnih istraživanja, sljedeće, drugo poglavlje donosi specifičnosti i ograničenja primijenjene metodologije, te opis izvora podataka. U trećem poglavlju

iznose se i komentiraju rezultati, a četvrto iznosi ključne zaključke, ograničenja i smjernice za buduća istraživanja.

2. METODOLOGIJA I PODACI

Temeljna hipoteza ovoga rada jest da se autori s promatranih ekonomskih fakulteta u Hrvatskoj najčešće grupiraju u koautorstva s dva do tri autora zbog regulative koja im na ovaj način omogućuje pripisivanje potpunog (nepodijeljenog) autorstva nad radom, premda je posao izrade rada podijeljen među autorima. Također, druga hipoteza pretpostavlja visok stupanj koeficijenta varijacije znanstvenog utjecaja (citiranosti) među autorima, odnosno da postoji relativno velik broj rijetko citiranih nastavnika u odnosu na relativno malen broj visoko citiranih autora, zbog čega prosječna citiranost mjerena aritmetičkom sredinom nije dobro mjerilo kolektivnoga znanstvenog utjecaja.

Prvi korak u formiranju baze podataka koja je korištena kao osnova bilo je prikupljanje aktualnog popisa nastavnika s osječkog, riječkog, splitskog i zagrebačkog Ekonomskog fakulteta (sva četiri fakulteta nadalje će se zajedno referirati akronimom EF). Ovi popisi preuzeti su sredinom lipnja 2021. sa službenih internetskih stranica EF uz pretpostavku da su stranice ažurne i predstavljaju realno stanje. To također znači da u analizu nisu uključeni svi bivši nastavnici EF: umirovljeni, preminuli, kao i oni koji više nisu u radnom odnosu s promatranim institucijama iz drugih razloga. Nije se moglo isključiti nedavno zaposlene asistente koji nisu bili u mogućnosti objavljivati radove, no s druge strane nisu isključivani ni stariji profesori koji će skoro u mirovinu.

Pod pojmom "nastavnici" ovdje se podrazumijevaju sve osobe u zvanjima asistenta, docenta, izvanrednog profesora, redovitog profesora, redovitog profesora u trajnom zvanju i profesora emeritusa, odnosno sve osobe koje drže nastavu na EF. Ukupno je promatran 521 nastavnik.

Za svakoga nastavnika potom su pretražena tri izvora podataka, i to:

1. Web of Science (WoS; <http://apps.webofknowledge.com>),
2. Scopus (<https://www.scopus.com/>) i
3. Google Scholar (<https://scholar.google.com>).

Navedeni su scijentometrijski izvori odabrani zato što se objavljivanje u WoS-u i Scopusu, uz javno dostupan Scholar profil, zahtijeva prema Pravilniku o uvjetima za izbor u znanstvena zvanja (Narodne novine, br. 28/17, 72/19 i 21/21). Dakle, istražena je cijela populacija svih nastavnika s EF, čime su u potpunosti izbjegnuti metodološki izazovi analize uzorka (reprezentativnost itd.). Sve tri promatrane baze podataka mogu obuhvaćati jedan te isti rad, no i ne moraju – zato se promatraju odvojeno.

U svrhu pretraživanja navedenih triju izvora načinjene su specijalizirane aplikacije (engl. "bots", odnosno "web-crawlers") koje su za svakoga nastavnika iz svakoga od izvora očitale i spremile pripadajući im broj citata i h-indeks.

Preuzimanje podataka izvršeno je potkraj lipnja 2021. Prikupljene podatke potom se provjeravalo¹ i filtriralo s obzirom na sljedeće kriterije:

- a) neki nastavnici imaju isto ime i prezime kao i drugi znanstvenici koji nisu s EF (slučajevi kombinacije čestog imena i čestog prezimena);
- b) nekim nastavnicima primarna afilijacija nije EF, već imaju dva radna mjesta, a položaj na EF im je sekundaran.

Pružatelji scijentometrijskih podataka oslanjaju se na to da znanstvenici sami vode računa o ažurnosti svojih profila, odnosno da se radovi korektno povezuju s autorima. Naravno, to nije uvijek slučaj te se događa da se pojedini radovi pogrešno pripisuju ili se uopće ne povezuju s pravim autorima. O tome valja voditi računa pri interpretaciji rezultata. Ovih slučajeva ima malo, no s obzirom na broj nastavnika, bilo je nemoguće provjeriti svakoga nastavnika pojedinačno, u svakoj od tri scijentometrijska izvora.

Dodatna ograničenja ovoga istraživanja proizlaze iz činjenice da su pojedini nastavnici (većinom ženskog spola) mijenjali prezime, pa i više puta, što katkad dovodi do nepovezivanja radova napisanih pod prethodnim prezimenom s radovima napisanima pod aktualnim prezimenom, i posljedično do nepotpune, odnosno nekorektno prikazane scijentometrije. U WoS-u također postoji otvoreno pitanje s osobama koje imaju često ime i prezime (npr. Ivan Horvat), gdje WoS agregira pokazatelje za različite osobe iz različitih područja, a koje imaju isto ime i prezime.

¹ Provjeravanje prikupljenih podataka vršilo se tako što su izrađeni "botovi" osim podataka o citiranosti preuzimali i afilijaciju autora, te su komparacijom afilijacija izlučeni oni koji nisu s EF.

Nakon preuzimanja i agregiranja podataka svi su nastavnici anonimizirani i dodijeljen im je broj, potpuno nasumično, no uz distinkciju sjedišta fakulteta. Npr. nastavniku X Y dodijeljena je šifra ZG235, pri čemu slova označuju sjedište fakulteta, a broj je nasumično dodijeljen u rasponu od 101 do ukupnog broja nastavnika na pojedinom fakultetu.

WoS, Scopus i Google Scholar su izvori za citiranost i h-indeks, a Crosbi je izvor za objavljene radove, odnosno za analizu brojnosti autora po radu. Baza podataka iz Crosbija (Hrvatska znanstvena bibliografija, <https://www.bib.irb.hr/>) preuzeta je 28. 5. 2021. i u nju su uključeni svi radovi koji su povezani s EF. Jasno, ako unositelj podataka prilikom upisa rada u Crosbi nije povezao svoj rad s institucijom, taj se rad neće nalaziti u preuzetoj bazi podataka. Inicijalna baza sadrži 23.753 rada (nakon isključivanja dvostrukih unosa), a prvi rad u bazi datiran je 1971. godine. Budući da su znanstvenici obvezni sve svoje radove unositi u Crosbi, za očekivati je da ona pokriva sve relevantne publikacije nastavnika u zemlji i inozemstvu.

Iz inicijalne Crosbi baze potom su isključene sljedeće kategorije radova:

- svi radovi objavljeni prije 2006.; promatrani su samo radovi objavljeni u posljednjih petnaest godina jer se od 1. siječnja 2006. počeo primjenjivati Pravilnik o uvjetima za izbor u znanstvena zvanja (u znanstvenoj zajednici poznat kao tzv. "stari" Pravilnik iz 2005., značajnije izmijenjen i dopunjen 2017.) koji je donio pravilo koje se slobodno može interpretirati kao "tri autora jednoga rada dijele koautorstvo tako da svakom od njih pripada punih 100% udjela u izradi toga rada",
- svi radovi koji nisu pripisani nijednom autoru, odnosno oni gdje je broj autora nula (što je moguće jer nastavnici samostalno unose podatke u Crosbi, a to otvara mogućnost mnogim pogreškama, pa i ovoj),
- ocjenski radovi: većinom disertacije i slični radovi kojima je nastavnik mentor, a ne autor,
- radovi koji su u Crosbi kategorizirani kao "ostale vrste radova": većinom popularni radovi,
- radovi koji su kategorizirani kao skripte,
- stručni radovi.

Nakon ovih filtracija, odnosno isključivanja početna je baza sužena na 12.041 rad.

Od navedenog 12.041 rada njih 9.354 (78%) moglo se povezati s barem jednim nastavnikom od ukupno 521 koji su u vrijeme izrade ovoga istraživanja zaposleni na EF. Kod preostalih 22% radova riječ je:

- a) o radovima bivših, umirovljenih i/ili preminulih nastavnika, ili
- b) radovima koji su nekorektno povezani s EF (npr. autori koji nisu s EF pri unosu u Crosbi povežu svoj rad s EF jer je članak bio predstavljen na konferenciji koju je organizirao EF, i sl.), ili
- c) radovima kod kojih su unositelji podataka u Crosbi nekorektno unijeli imena autora (tipfeleri, ili zamjena imena za prezime, ili skraćivanje imena i sl.), te ih stoga nije bilo moguće povezati sa šiframa nastavnika, ili
- d) radovima kod kojih su autori promijenili prezime te ih stoga nije bilo moguće povezati sa šiframa nastavnika.

Konačno, iz skupa od 9.354 potom su razdvojena dva podskupa:


- a) 2.637 radova s dva autora koji su trenutno nastavnici na EF, i
- b) 1.002 rada koji imaju tri autora (također samo oni koji su u vrijeme izrade ovoga rada nastavnici na EF).

Analiza podataka vršila se na odabranom skupu ili podskupu ovisno o objektu promatranja, odnosno ovisno o ciljevima obrade, što je elaborirano u rezultatima.

3. REZULTATI I DISKUSIJA

Ukupan broj nastavnika na EF iznosi 521, od čega više od pola – 53%, njih 277 – čine nastavnici s Ekonomskog fakulteta u Zagrebu, dok je raspodjela na ostalima relativno podjednaka (Grafikon 1.). U Osijeku su u vrijeme prikupljanja podataka bila zaposlena 73 nastavnika, u Rijeci 80, a u Splitu 91. Valja ponoviti, svi rezultati su referentni za kraj lipnja 2021.

Grafikon 1. Distribucija nastavnika po EF



Izvor: izračun autora.

Tablica 1. donosi rezultate promatranja citiranosti za sve nastavnike s EF. Stupci u navedenoj tablici opisuju kako slijedi:

- stupac 1. – scijentometrijski izvor prikupljenih podataka,
- stupci 2. i 3. – broj autora koji su pronađeni u navedenom izvoru, te sukladno tome postotak od ukupnog broja nastavnika (521); pokazuje da npr. od ukupno 521 nastavnika s EF za njih 88,5% (odnosno za 461) pronađeni su podaci u WoS-u,
- stupac 4. – scijentometrijski pokazatelji: ukupan broj citata po autoru i h-indeks kojega je razvio Hirsch (2005), a koji odražava produktivnost autora na temelju broja njegovih publikacija i broja citata tih publikacija,
- stupci 5. i 6. – pokazatelji centralne tendencije,
- stupci 7. i 8. – pokazatelji raspona (minimum i maksimum), te
- stupci 9. i 10. – pokazatelji raspršenosti (standardna devijacija i koeficijent varijacije kao omjer standardne devijacije i aritmetičke sredine).

Vidljivo je da, unatoč regulativi koja propisuje da svaki nastavnik mora imati javno dostupan Google Scholar profil, njih 14,2% odnosno 74 ne ispunjava ovu normu. Razlike između aritmetičke sredine i medijana kod h-indeksa su nevelike, no kod citiranosti očito je kako krajnosti (nastavnici s velikim brojem citata) povlače aritmetičku sredinu naviše, što se reflektira i na koeficijentima varijacije. S obzirom na ovo, u daljnjoj analizi potrebno se fokusirati na medijan kao mjeru centralne tendencije koja je manje podložna ekstremima, te su stoga rangiranja vršena prema medijanu (grafikoni 2. do 6.).

Tablica 1. Statistički pokazatelji citiranosti i h-indeksa iz odabranih scijentometrijskih izvora za sve nastavnike s ekonomskih fakulteta u Hrvatskoj u lipnju 2021.

Izvor	Broj autora	% od uk. br. autora	Pokazatelj	Aritm. sredina	Medijan	Min.	Max.	Stand. dev.	Koef. var.
1	2	3	4	5	6	7	8	9	10
Google Scholar	447	85,8	citiranost	273,71	127	0	3430	457,08	166,99
			h-indeks	6,26	6	0	32	4,81	76,76
Scopus	368	70,6	citiranost	50,86	14	0	1403	123,79	243,41
			h-indeks	2,73	2	0	20	2,51	92,09
WoS	461	88,5	citiranost	34,65	9	0	888	82,96	239,45
			h-indeks	2,21	2	0	18	2,19	99,07

Izvor: izračun autora.

Na Ekonomskom fakultetu u Osijeku u odnosu na ostale fakultete najveći je postotak nastavnika koji imaju otvorene Google Scholar i WoS profile. Po većini ostalih scijentometrijskih pokazatelja nalazi se ispod prosjeka svih EF (Tablica 2.).

Tablica 2. Statistički pokazatelji citiranosti i h-indeksa iz odabranih scijentometrijskih izvora za sve nastavnike s Ekonomskog fakulteta u Osijeku u lipnju 2021.

Izvor	Broj autora	% od uk. br. autora	Poka- zatelj	Aritm. sredina	Medijan	Min.	Max.	Stand. dev.	Koef. var.
1	2	3	4	5	6	7	8	9	10
Google Scholar	68	93,2	citiranost	239,46	99	0	2696	433,15	180,89
			h-indeks	5,84	5	0	19	4,46	76,41
Scopus	37	50,7	citiranost	40	9	1	304	69,82	174,55
			h-indeks	2,51	2	1	8	1,92	76,54
WoS	70	95,9	citiranost	24,23	9	0	335	50,64	209
			h-indeks	1,86	2	0	9	1,59	85,65

Izvor: izračun autora.

Slično kao i u Osijeku, nastavnici iz Rijeke su po većini mjerila u ovom istraživanju ispod prosjeka, s iznimkom citiranosti i h-indeksa u Scopusu (Tablica 3.).

Tablica 3. Statistički pokazatelji citiranosti i h-indeksa iz odabranih scijentometrijskih izvora za sve nastavnike s Ekonomskog fakulteta u Rijeci u lipnju 2021.

Izvor	Broj autora	% od uk. br. autora	Poka- zatelj	Aritm. sredina	Medijan	Min.	Max.	Stand. dev.	Koef. var.
1	2	3	4	5	6	7	8	9	10
Google Scholar	74	92,5	citiranost	129,14	59	0	1077	182,96	141,68
			h-indeks	4,55	4	0	16	3,57	78,39
Scopus	53	66,3	citiranost	57,89	12	0	838	152,74	263,86
			h-indeks	2,83	2	0	17	3,14	111,03
WoS	70	87,5	citiranost	29,16	6	0	552	82,43	282,7
			h-indeks	1,99	2	0	13	2,12	106,57

Izvor: izračun autora.

Nastavnici iz Splita su iznad prosjeka po svim scijentometrijskim pokazateljima, osim citiranosti u Scopusu ako se promatra po aritmetičkoj sredini, no valja zamijetiti i da je koeficijent varijacije bitno niži u Splitu nego kod prosjeka, te da su varijacije među nastavnicima niže, odnosno da je raspodjela ujednačenija (Tablica 4.).

Tablica 4. Statistički pokazatelji citiranosti i h-indeksa iz odabranih scijentometrijskih izvora za sve nastavnike s Ekonomskog fakulteta u Splitu u lipnju 2021.

Izvor	Broj autora	% od uk. br. autora	Pokazatelj	Aritm. sredina	Medijan	Min.	Max.	Stand. dev.	Koef. var.
1	2	3	4	5	6	7	8	9	10
Google Scholar	78	85,7	citiranost	279,62	215	2	1147	279,68	100,02
			h-indeks	6,95	7	1	17	3,74	53,79
Scopus	73	80,2	citiranost	34,15	18	0	234	47,84	140,09
			h-indeks	2,26	2	0	6	1,53	67,59
WoS	85	93,4	citiranost	34,06	12	0	390	55,28	162,3
			h-indeks	2,24	2	0	9	1,82	81,57

Izvor: izračun autora.

Ekonomski fakultet u Zagrebu kao značajno veći od ostalih u usporedbi ima i nadprosječne scijentometrijske pokazatelje, te ima nastavnike s najvećim maksimumima pokazatelja. No valja zamijetiti i da su koeficijenti varijacije veći od prosjeka, te je shodno tome ujednačenost među 277 nastavnika iz Zagreba manja od prosjeka (Tablica 5.).


Tablica 5. Statistički pokazatelji citiranosti i h-indeksa iz odabranih scijentometrijskih izvora za sve nastavnike s Ekonomskog fakulteta u Zagrebu u lipnju 2021.

Izvor	Broj autora	% od uk. br. autora	Pokazatelj	Aritm. sredina	Medijan	Min.	Max.	Stand. dev.	Koef. var.
1	2	3	4	5	6	7	8	9	10
Google Scholar	227	81,95	citiranost	329,07	133	0	3430	555,8	168,9
			h-indeks	6,71	6	0	32	5,43	80,86
Scopus	205	74,01	citiranost	56,95	15	0	1403	140,66	246,98
			h-indeks	2,91	2	0	20	2,69	92,56
WoS	236	85,2	citiranost	39,58	10	0	888	97,81	247,14
			h-indeks	2,36	2	0	18	2,46	103,84

Izvor: izračun autora.

Grafikon 2. vizualizira podatak iz šestog stupca u tablicama 2. do 5., odnosno rangira fakultete po medijanu citiranosti. Zbog različite metodologije izračuna citata scijentometrijskih izvora ordinata ima logaritamsko mjerilo. Uočljivo je kako je poredak na ljestvici po gotovo svim izvorima jednak, te je na prvom mjestu Split, na drugom Zagreb, trećem Osijek, a na četvrtom Rijeka (osim kod Scopusa gdje je Rijeka treća, a Osijek četvrti).

Grafikon 2. Medijan citiranosti nastavnika s odabranih ekonomskih fakulteta u Republici Hrvatskoj u lipnju 2021.



Izvor: izračun autora.

Tablica 6. fokusira citiranost u WoS-u i prikazuje distribuciju frekvencija (apsolutne i postotne) prema prikladnim razredima, kako bi bilo vidljivo koliki je udio nastavnika bez citata, a koliki je onih s više od deset, sto i dvjesto. Najveći dio nastavnika (36%) ima između 11 i 100 citata, a nakon toga čak 28% nastavnika nema citata, odnosno za njih nema podataka.

Tablica 6. Distribucija citata po nastavniku svih ekonomskih fakulteta u Hrvatskoj u WoS-u, u lipnju 2021.


Broj citata u WoS-u	Broj nastavnika	%	% kumulativno
Nula ili nema podataka	145	28%	27,83%
1	28	5%	33,21%
2 do 10	126	24%	57,39%
11 do 100	190	36%	93,86%
101 do 200	20	4%	97,70%
201 do 888	12	2%	100,00%

Izvor: izračun autora.

Što se tiče komparativne analize h-indeksa, medijan kod WoS-a i Scopusa je za sve isti i iznosi 2, dok zbog drugačije metodologije prikupljanja podataka kod Google Scholar h-indeks varira od 7 (EFST) do 4 (EFRI), što je također vidljivo u tablicama 2. do 5.

Prethodna analiza usredotočila se na mjere centralne tendencije (točnije na medijane), no promotre li se pojedinačni nastavnici i rangiraju prema citiranosti u WoS-u i Scopusu, jasno je kako su i za WoS i za Scopus to mahom iste osobe, te je rang ljestvica prvih deset gotovo ista (Grafikon 3.). Nastavnik pod šifrom ZG150 najviše je rangiran po citiranosti i u WoS-u i u Scopusu. Nastavnici pod šiframa ST163 i OS128 nalaze se u prvih deset po citiranosti u WoS-u, ali nisu među prvih deset po citiranosti u Scopusu.

Grafikon 3. Prvih deset nastavnika s ekonomskih fakulteta u Hrvatskoj po citiranosti u WoS-u i Scopusu u lipnju 2021.




Izvor: izračun autora.

Očito je kako se rang rezultata iz WoS-a i Scopusa velikim dijelom podudara, no budući da Google Scholar pokriva šire područje publikacija, ne samo znanstvenih članaka nego i web stranica, blogova, novina itd., rang lista citiranosti prvih deset autora kod Scholar (Grafikon 4.) razlikuje se od

prethodne (Grafikon 3.). Scholar se stoga može promatrati kao alat za stjecanje uvida u širi javni utjecaj nastavnika, ne samo znanstveni. Iz ovog se razloga čak petoro nastavnika koji su u "top 10" citiranosti u Scholaru (Grafikon 4.) uopće ne nalaze na rang listi "top 10" citiranosti u WoS-u i Scopusu (Grafikon 3.). Također, među prvih deset najcitiranijih nastavnika s EF u Scholaru samo jedan nije iz Zagreba (OS182).

Grafikon 4. Prvih deset nastavnika s ekonomskih fakulteta u Hrvatskoj po citiranosti u Google Scholaru u lipnju 2021.



Izvor: izračun autora.

Nakon analize citiranosti sljedeći doprinos ovoga rada odnosi se na analizu suradnje, odnosno kohezije autora pri pisanju i objavljivanju radova, što se praktično odnosi na analizu statistike brojnosti autora po jednom radu.

Počevši od inicijalne Crosbi baze od 23.753 rada te isključivanjem radova po kriterijima koji su navedeni u metodologiji, razmatrao se uzorak od 12.041 rada. Ovaj skup potom se promatrao prema brojnosti autora po jednom radu (Tablica 7.).

Tablica 7. Deskriptivna statistika broja autora po jednom radu u uzorku iz Crosbi baze od siječnja 2006. do lipnja 2021.

Fakultet	Broj radova	Aritm. sredina	Medijan	Min.	Max.	Std. dev.	Koef. var.
EFOS	1776	2,27	2	1	25	1,28	56,62
EFRI	2152	2,23	2	1	25	1,20	53,83
EFST	1705	2,16	2	1	21	1,08	50,25
EFZG	6408	2,30	2	1	50	1,64	71,20
SVI EF	12041	2,26	2	1	50	1,45	63,99

Izvor: izračun autora.

Deskriptivna je statistika u ovom slučaju manjkava i nedovoljna za pravu sliku objekta istraživanja jer se čini da u prosjeku radovi imaju po dva autora, te da među fakultetima nema značajnijih razlika. Bolji uvid u to koliko po jednom radu ima autora dobiva se promatranjem distribucije broja autora po radovima (Tablica 8.).

Tablica 8. Distribucija autora po jednom radu u uzorku iz Crosbi baze od siječnja 2006. do lipnja 2021., stratificirano prema fakultetima


Fakultet	Broj autora po radu	Broj radova	Broj radova, kumulativno	%	% kumulativno
EFOS	1	473	473	26,63	26,63
	2	524	997	29,50	56,14
	3	713	1710	40,15	96,28
	4	37	1747	2,08	98,37
	5	17	1764	0,96	99,32
	6 i više	12	1776	0,68	100,00
EFRI	1	622	622	28,90	28,90
	2	635	1257	29,51	58,41
	3	806	2063	37,45	95,86
	4	38	2101	1,77	97,63
	5	29	2130	1,35	98,98
	6 i više	22	2152	1,02	100,00
EFST	1	481	481	28,21	28,21
	2	587	1068	34,43	62,64
	3	582	1650	34,13	96,77
	4	41	1691	2,40	99,18
	5	6	1697	0,35	99,53
	6 i više	8	1705	0,47	100,00
EFZG	1	1680	1680	26,22	26,22
	2	2078	3758	32,43	58,65
	3	2299	6057	35,88	94,52
	4	202	6259	3,15	97,67
	5	82	6341	1,28	98,95
	6 i više	67	6408	1,05	100,00

Izvor: izračun autora.

Otprilike jedna trećina (Split) do oko 40% (Osijek) svih znanstvenih radova s hrvatskih ekonomskih fakulteta imaju po tri autora, a oko 70% svih radova na svim EF imaju po dva ili tri autora. Istodobno, četiri i više autora imaju svega 4 do 5% radova, što označava vrlo jasan prag između radova koji

imaju manje od tri i više od tri autora. Grafikon 5. pokazuje raspodjelu broja autora po jednom radu na svim EF.

Grafikon 5. Distribucija autora po jednom radu u uzorku iz Crosbi baze od siječnja 2006. do lipnja 2021., stratificirano prema broju autora



Izvor: izračun autora.

Tablica 9. prezentira rezultate istraživanja sukladno prethodno iznesenoj metodologiji u kojoj su nabrojeni radovi s dva autora s EF na jednome radu. Konkretno, to znači da prvorangirani autori ZG199 i ZG203 imaju ukupno 50 radova na kojima su partneri, i to u bilo kojoj kombinaciji (nekad je prvi autor ZG203, a nekad je to ZG199). Važno je napomenuti da nabrojeni radovi mogu imati i dodatne autore osim navedenog para. Dakle, u ovih 50 radova ubrojeni su i radovi na kojima uz navedeni dvojac katkad postoji i treći autor unutar ili izvan promatranih EF koji u redoslijedu autora može biti na prvom, drugom, ili trećem mjestu (npr. rad "ABC" kojemu su autori ZG199, X, ZG203; zatim rad "DEF" kojemu su autori Y, ZG203, ZG199, itd.). Stoga promatrani partneri ne moraju nužno biti jedini i isključivi autori zajedničkih radova. Prezentirani redoslijed autora (A, B) je arbitran.

Tablica 9. Partnerstva autora s ekonomskih fakulteta u Hrvatskoj s preko dvadeset zajedničkih radova u uzorku iz Crosbi baze od siječnja 2006. do lipnja 2021.

Koautori u partnerstvu		Broj zajedničkih radova
A	B	
ZG203	ZG199	50
ST185	ZG339	41
OS106	OS147	40
ZG152	ZG217	29
ZG337	ZG275	28
ZG208	ZG184	25
ZG330	ZG279	24
RI128	RI137	23
ST130	ST178	22
ZG130	ZG255	21
ST163	ST177	21
ZG283	ZG268	21

Izvor: izračun autora.

U ovom radu termin "trijada" koristi se za opisivanje grupe od tri autora koji zajedno pišu i objavljuju publikacije, pri čemu se redoslijed autora (tko je prvi, tko drugi, a tko treći) izmjenjuje od rada do rada. Uzevši u obzir ograničenja i isključenja navedena u metodologiji ovoga istraživanja (isključenje svih radova objavljenih prije 2006., itd.), prvorangirana trijada ima najmanje dvadeset zajedničkih radova. Praktično, to znači da si je pri napredovanju svaki nastavnik u ovoj trijadi pripisao puno autorstvo nad svakim od ovih dvadeset radova. Šesnaest je trijada sa sedam i više zajedničkih radova (Tablica 10.). Kao i prethodno, prezentirani redoslijed autora (A, B, C) je arbitran.

Tablica 10. Trijade autora s ekonomskih fakulteta u Hrvatskoj sa sedam i više zajedničkih radova u uzorku iz Crosbi baze od siječnja 2006. do lipnja 2021.

Koautori u trijadi			Broj zajedničkih radova
A	B	C	
RI124	RI156	ZG235	20
RI148	RI132	RI154	11
ZG125	ZG265	ZG327	11
ZG118	ZG279	ZG330	10
ST106	ST174	ZG347	9
ZG199	ZG212	ZG119	9
ZG226	ZG165	ZG258	9
ZG244	ZG266	ZG121	9
ST122	ST130	ST178	8
ST185	ZG339	ST154	8
ST185	ZG339	ST186	8
ZG143	ZG282	ZG353	8
ZG152	ZG356	ZG217	8
ZG165	ZG117	ZG226	8
ZG369	ZG199	ZG203	8
ZG116	ZG272	ZG334	7

Izvor: izračun autora.

Postoji li kakva veza između broja zajedničkih radova i citiranosti koautora? Može li se postaviti teza da citiraniji autori imaju tendenciju više surađivati, odnosno da postoji veća kohezija kod visoko-citiranih autora? Uzme li se prosječna WoS citiranost za autore u partnerstvu (Tablica 11.) odnosno trijadi (Tablica 12.) kao nezavisna varijabla, i broj njihovih zajedničkih radova kao zavisna varijabla, u OLS modelu R^2 iznosi nula, a nezavisna varijabla je visoko nesignifikantna. Ovo je u skladu s prethodnim istraživanjima (Moosa, 2017) i indicira kako citati nisu povezani s brojem autora.

Tablica 11. Prosječna WoS citiranost partnerstva autora s ekonomskih fakulteta u Hrvatskoj s preko dvadeset zajedničkih radova u uzorku iz Crosbi baze od siječnja 2006. do lipnja 2021.

Koautori u partnerstvu		WoS citiranost autora A	WoS citiranost autora B	Prosječna WoS cit. partnerstva	Broj zajedničkih radova
A	B				
ZG203	ZG199	50	55	52,5	50
ST185	ZG339	121	71	96	41
OS106	OS147	24	1	12,5	40
ZG152	ZG217	58	55	56,5	29
ZG337	ZG275	131	600	365,5	28
ZG208	ZG184	62	0	31	25
ZG330	ZG279	8	70	39	24
RI128	RI137	11	13	12	23
ST130	ST178	158	58	108	22
ZG130	ZG255	55	12	33,5	21
ST163	ST177	390	9	199,5	21
ZG283	ZG268	62	65	63,5	21

Izvor: izračun autora.

Navedeno ukazuje da suradnja autora nije funkcija njihove citiranosti, već da se autori povezuju po drugim (ovdje nepromatranim) osnovama.

Tablica 12. Prosječna WoS citiranost trijada autora s ekonomskih fakulteta u Hrvatskoj sa sedam i više zajedničkih radova u uzorku iz Crosbi baze od siječnja 2006. do lipnja 2021.

Koautori u trijadi			WoS citiranost autora A	WoS citiranost autora B	WoS citiranost autora C	Prosječna WoS cit. trijade	Broj zajedničkih radova
A	B	C					
RI124	RI156	ZG235	25	48	82	51,67	20
RI148	RI132	RI154	0	6	0	2	11
ZG125	ZG265	ZG327	91	20	57	56	11
ZG118	ZG279	ZG330	21	70	8	33	10
ST106	ST174	ZG347	50	8	82	46,67	9
ZG199	ZG212	ZG119	55	42	0	48,5	9
ZG226	ZG165	ZG258	111	31	29	57	9
ZG244	ZG266	ZG121	29	13	13	18,33	9
ST122	ST130	ST178	5	158	58	73,67	8
ST185	ZG339	ST154	121	71	9	67	8
ST185	ZG339	ST186	121	71	46	79,33	8
ZG143	ZG282	ZG353	15	6	0	7	8
ZG152	ZG356	ZG217	58	43	55	52	8
ZG165	ZG117	ZG226	31	57	111	66,33	8
ZG369	ZG199	ZG203	28	55	50	44,33	8
ZG116	ZG272	ZG334	2	0	6	2,67	7

Izvor: izračun autora.

Konačno, logično je i razumljivo da će najprije surađivati i suobjavljivati autori s iste institucije, tj. koji imaju istu matičnu afilijaciju. No isključuje li se kolaboracije s iste institucije, zgodno je promotriti s kojih institucija nastavnici najviše međusobno surađuju pri objavljivanju radova, odnosno koliko ima radova kojima autori imaju različite afilijacije. Tablica 13. pokazuje postotak suradnji u zajedničkim radovima radova s dva autora (gdje je jedan s jedne institucije, a drugi s druge), kao i radova s tri autora (gdje su dva s jedne institucije, a treći s druge – u bilo kojem redoslijedu). Trilateralnih radova – gdje su autori s tri različite institucije – ima svega nekoliko, odnosno zanemarivo malo, te stoga nisu prikazani. Rezultati ne iznenađuju te

ukazuju da je postotak suradnji zapravo funkcija veličine matičnog fakulteta; logično je da će najviše suradnji biti između Zagreba i Splita jer su to i najveći fakulteti mjereno i brojem nastavnika, i drugim mjerilima.

Tablica 13. Učestalost suradnji autora s ekonomskih fakulteta u Hrvatskoj u uzorku iz Crosbi baze od siječnja 2006. do lipnja 2021.

Matične institucije s kojih autori surađuju	Postotak suradnji u zajedničkim radovima
EFZG – EFST	64%
EFZG – EFRI	12%
EFST – EFRI	9%
EFZG – EFOS	8%
EFRI – EFOS	6%
EFST – EFOS	1%
Ukupno	100%

Izvor: izračun autora.

4. ZAKLJUČAK

Cilj i svrha ovoga rada su prikazati citiranost i povezanost nastavnika ekonomskih fakulteta u Osijeku, Rijeci, Splitu i Zagrebu, te inicirati diskusiju o smislenosti postojeće regulative koja uređuje raspodjelu udjela u autorstvu rada. Preuzete su postojeće i kreirane nove baze podataka iz kojih je bilo moguće analizirati scijentometrijske pokazatelje i suradnju autora pri objavljivanju radova. Analiziran je 12.041 rad objavljen nakon 2005. godine i 521 nastavnik.

Zagrebački Ekonomski fakultet daleko je najveći fakultet svoje vrste u Hrvatskoj po mnogim mjerilima, pa tako i po broju nastavnika. No to ne znači da je i njegov znanstveni utjecaj najveći; premda ima pojedine briljantne nastavnike koji iskazuju najviše scijentometrijske pokazatelje u Hrvatskoj, u prosjeku je ipak na drugom mjestu, iza splitskog Ekonomskog fakulteta. Osječki i riječki ekonomski fakulteti izmjenjuju se na trećem i četvrtom mjestu.

Što se tiče suradnje nastavnika, osoba koja promatra ovaj sustav izvana (npr. iz druge zemlje i/ili drugog znanstvenog područja) bi analizom rezultata ovoga rada mogla zaključiti da je u Hrvatskoj za izradu znanstvenog rada u području ekonomije optimalno oformiti tim od do tri osobe, te da već četvrti član čini tim neproduktivnim i/ili neučinkovitim. To je stoga što podaci pokazuju jasan i značajan prag; 95 do 97% radova ima do tri autora, a samo 3 do 5% ima četiri i više. Naravno, to je posljedica regulative, a citiranost nije korelirana s brojem autora.

Legitimno je regulativom poticati znanstvenu suradnju i koheziju autora jer se time može postići komplementarnost aktivnosti čiji je učinak veći od zbroja partikularnih doprinosa, no pritom valja imati na umu da jednako vrednovanje samostalnog autorstva i trijade autora u određenoj mjeri omalovažava i degradira samostalnoga autora, onoga koji je potpuno sam kreirao cjelinu (100%) svoga rada time što njegov trud i napor izjednačava s trijadom u kojoj se svakom od tri autora pojedinačno pripisuje 100% truda i napora u stvaranju rada, iako je to matematički i realno nemoguće. Dva i tri koautora stavljaju se u povlašteni položaj, a pojedinačnoga se autora diskriminira paradoksalnom i matematički nemogućom raspodjelom udjela u višeautorskim radovima. Stoga se preporučuje preispitati suštinu postojeće regulative te se predlaže smanjenje pripisivanja udjela koautorstva na udio manji od sto.

Specifični znanstveni doprinos ovoga rada sastoji se u tome što prethodna bibliometrijska istraživanja i slične analize citiranosti i povezanosti nastavnika ekonomskih fakulteta u Hrvatskoj ne postoje, te u tom smislu ovaj rad predstavlja novinu. Također, doprinos se očituje u formiranju sasvim novih baza podataka koje su potom statistički obrađene. Manjkavosti se ogledaju prije svega u nužnim metodološkim ograničenjima koja je valjalo primijeniti kako bi se ikakva analiza uopće mogla provesti. Stoga, zbog nužnih metodoloških izazova i restrikcija rezultati prezentirani u ovom radu nisu egzaktni i služe ilustraciji, a ne preciznom prikazu stanja.

U budućim istraživanjima bilo bi korisno proširiti područje istraživanja i na druge znanstvenike iz područja ekonomije (s instituta, privatnih visokih učilišta itd.), te proširiti vremenski horizont i na radove objavljene prije 2006. godine, kao i na radove bivših zaposlenika, te izvršiti komparativnu analizu regulative u usporedivim zemljama. Također, pitanje doprinosa i redoslijeda navođenja autora zanimljivo je i važno, te bi valjalo opisati konkretni doprinos autora u koautorskim radovima.

LITERATURA

- Bartneck, C., & Kokkermans, S. (2011). Detecting H-Index Manipulation Through Self-Citation Analysis. *Scientometrics*, 87(1), 85–98. <https://doi.org/10.1007/s11192-010-0306-5>
- Blau, P. M. (1996). *The Organization of Academic Work* (2nd edition). Routledge. <http://journals.sagepub.com/doi/10.1177/0270467696016001112>
- Boyer, E. L. (1997). *Scholarship Reconsidered: Priorities of the Professoriate* (1st edition). Jossey-Bass.
- Fong, E. A., & Wilhite, A. W. (2017). Authorship and Citation Manipulation in Academic Research. *PLOS ONE*, 12(12), e0187394. <https://doi.org/10.1371/journal.pone.0187394>
- Hartley, J. (2003). Single Authors Are Not Alone: Colleagues Often Help. *Journal of Scholarly Publishing*, 34(2), 108–113. <https://doi.org/10.3138/jsp.34.2.108>
- Hirsch, J. E. (2005). An Index to Quantify an Individual's Scientific Research Output. *Proceedings of the National Academy of Sciences*, 102(46), 16569–16572. <https://doi.org/10.1073/pnas.0507655102>
- Moosa, I. A. (2017). Citations, Journal Ranking and Multiple Authorships: Evidence Based on the Top 300 Papers in Economics. *Applied Economics Letters*, 24(3), 175–181. <https://doi.org/10.1080/13504851.2016.1176104>
- Pravilnik o uvjetima za izbor u znanstvena zvanja, Pub. L. No. Narodne novine, br. 28/17, 72/19 i 21/21 (2017).
- Newman, M. E. J. (2001). The Structure of Scientific Collaboration Networks. *Proceedings of the National Academy of Sciences of the United States of America*, 98(2), 404–409. <https://doi.org/10.1073/pnas.021544898>
- Oxford Lexico. (2021). *Definition of SCIENTOMETRICS by Oxford Dictionary on Lexico.com*. Lexico Dictionaries by Oxford. <https://www.lexico.com/en/definition/scientometrics>
- Sajter, D. (2021). Scientific Impact of Central and Eastern European Higher Education Lecturers. *Naše gospodarstvo/Our economy*, 67(3), str. 17-28. <https://doi.org/10.2478/ngoe-2021-0014>
- Žugaj, M., Hutinski, Ž., & Bojanić, M. (1993). Bibliometrijska istraživanja temeljnih značajki članaka u časopisu "Ekonomski pregled" (1980 – 1990). *Ekonomski vjesnik: Review of Contemporary Entrepreneurship, Business, and Economic Issues*, VI(1), 89–97.

SCIENTIFIC RESULTS AND COOPERATION OF AUTHORS FROM THE FACULTIES OF ECONOMICS IN OSIJEK, RIJEKA, SPLIT AND ZAGREB

Abstract

The purpose of this paper is to collect and analyse data on the teaching staff of the Faculties of Economics in Osijek, Rijeka, Split and Zagreb with regard to their scientific impact and cooperation in publishing. An analysis of scientometrics (citations, h-indexes) and co-authorship of papers was performed. Data were collected from Google Scholar, Web of Science, Scopus and the Croatian Scientific Bibliography (CROSBIB) using specialized search engines ("bots") developed for this purpose.

Certain academic staff of the Faculty of Economics in Zagreb exhibits the highest scientometric indicators in Croatia, but on average (measured by the median) the Zagreb Faculty is in second place after all, behind the Faculty of Economics in Split. The Faculties of Economics in Osijek and Rijeka alternate in third and fourth place. Most of the papers have two or three authors, and very few have four or more. This is a consequence of regulations, and citation is not correlated with the number of authors. The results are important for the assessment of scientific activity and progress, and for initiating a discussion on the evaluation of co-authorships in Croatia.

Keywords: *economists, Faculty of Economics, scientometrics, h-index, citations.*

JEL klasifikacija: E32, E43, E52, F44
Pregledni rad

ČINI LI EUROZONA OPTIMALNO VALUTNO PODRUČJE? ANALIZA USKLAĐENOSTI POSLOVNIH CIKLUSA¹

Karla Radić*
Vladimir Arčabić**

SAŽETAK

U radu se analizira usklađenost poslovnih ciklusa zemalja članica Europske monetarne unije u sklopu teorije optimalnog valutnog područja. Drugi cilj rada je ispitati primjenjivost monetarnog pravila za monetarnu politiku europodručja. Kada je usklađenost poslovnih ciklusa visoka, tada je veća vjerojatnost da su zemlje članice izložene sličnim šokovima te djelovanje zajedničke monetarne politike u tom slučaju ne stvara dodatne troškove. U suprotnome, niska usklađenost poslovnih ciklusa sugerira postojanje asimetričnih šokova koji zahtijevaju različite odgovore ekonomske politike, što stvara troškove. Analizom je utvrđen rast usklađenosti kod svih zemalja tijekom financijske i koronakrize. Od 2007. godine naovamo kod većine zemalja prisutna je jaka povezanost s cikličkim kretanjem eurozone, osim tijekom razdoblja dužničke krize. Dužnička kriza je ujedno i najveći dosadašnji izazov europodručja, jer su pojedine periferne zemlje ostale bez mogućnosti dodatne stabilizacije gospodarstva zajedničkom monetarnom

* Karla Radić, Ekonomski fakultet Sveučilišta u Zagrebu (e-mail: kradic1@net.efzg.hr).

** Doc. dr. sc. Vladimir Arčabić, Ekonomski fakultet Sveučilišta u Zagrebu (e-mail: varcabic@efzg.hr).

¹ Rad je nastao u sklopu istraživanja za diplomski rad pod nazivom "Analiza usklađenosti poslovnih ciklusa i primjenjivost monetarnog pravila u zemljama europodručja" kandidatkinje Karle Radić pod mentorstvom doc. dr. sc. Vladimira Arčabića. Rad je obranjen na Ekonomskom fakultetu u Zagrebu 23. 9. 2021.

politikom. Ipak, eurozona čini optimalno valutno područje te su koristi koje proizlaze iz članstva u Uniji veće od troškova. Vezano uz drugi cilj rada, rezultati pokazuju da se politika Europske središnje banke može opisati monetarnim pravilom s uključenim pomakom kamatne stope. S druge strane, model originalnoga Taylorova pravila nije prikladan za prikaz određivanja kamatne stope u eurozoni.

Ključne riječi: Taylorovo pravilo, usklađenost poslovnih ciklusa, zaglađivanje kamatne stope.

1. UVOD

Usklađenost poslovnih ciklusa, jedan je od kriterija teorije optimalnog valutnog područja koje potencijalne članice monetarnog i valutnog područja trebaju zadovoljiti kako bi u potpunosti iskoristile prednosti monetarne unije. Tijekom godina, usklađenost poslovnih ciklusa zemalja članice monetarne unije postaje jedan od tzv. metakriterija teorije optimalnog valutnog područja. Važnost usklađenosti očituje se u primjeni jedinstvene monetarne politike i njezinoj mogućnosti kontracikličkog djelovanja. Dodatno, Taylor (1993) predlaže pravilo u kojem nominalna kamatna stopa ovisi o inflaciji te jazu inflacije i dohotka. Od tada, tema velikog broja istraživačkih radova je testiranje i razvijanje jednostavnih pravila monetarne politike. Pravilo se u literaturi prikazuje kao korisno zbog jednostavnosti i mogućnosti prilagođavanja potrebama nositelja monetarne politike. U ovome radu ispituje se usklađenost poslovnih ciklusa pojedinih zemalja članica europodručja s agregiranim područjem EA-19. Mjera usklađenosti uključuje pomičnu korelaciju s petogodišnjim pomičnim prozorom. Zemlje se po zajedničkim karakteristikama grupiraju te se analizira povezanost cikličkih kretanja kroz vrijeme. Drugo, procjenjuje se nominalna kamatna stopa prema različitim oblicima Taylorova pravila. Regresijskom analizom ispituje se prikladnost pojedinih pravila i odabire najbolja reakcijska funkcija za opis monetarne politike Europske središnje banke.

Kao najvažniji rezultat može se istaknuti činjenica da je razdoblje od 2007. godine obilježeno visokim razinama usklađenosti kod većina zemalja članica. Nakon toga, uz iznimku dužničke krize, skoro sve zemlje pokazuju srednju do jaku povezanost s poslovnim ciklusima eurozone. Faze recesija obilježene su relativno visokim razinama usklađenosti, dok su razdoblja ekspanzija karakterizirane relativno nižim razinama povezanosti. Primjerice,

razdoblje neposredno prije i nakon financijske krize iz 2008. godine i recesija uzrokovana pandemijom obilježeni su rastom i visokom povezanošću cikličkih kretanja članica s onima europodručja. Što se tiče analize monetarnih pravila, regresijska analiza je pokazala kako Europska središnja banka postupno uvodi promjene u monetarnoj politici. Takvo ponašanje je obuhvaćeno varijablom zaglađivanja kamatne stope. Prema rezultatima, može se zaključiti da centralna banka odabire voditi monetarnu politiku prema monetarnim pravilima, umjesto diskrecijske politike.

Rad je podijeljen u pet dijelova. Poslije uvoda, slijedi pregled literature o usklađenosti poslovnih ciklusa i procjeni monetarnog pravila za europodručje. U trećem dijelu opisani su podaci i metodologija. Četvrti dio sadrži rezultate, dok posljednje poglavlje obuhvaća najvažnije rezultate i implikacije za nositelje monetarne politike.

2. PREGLED LITERATURE

Usklađenost poslovnih ciklusa postala je tema mnogih rasprava i debata nakon razvoja teorije Optimalnog valutnog područja (Mundell, 1961; McKinnon, 1963; Kenen, 1969) i stvaranja Europske monetarne unije (EMU). Naime, teorija se sastoji od više preduvjeta koje bi zemlje članice trebale zadovoljiti kako bi Unija činila optimalno valutno područje. Ključnu ulogu ima usklađenost poslovnih ciklusa, zbog troškova gubitka samostalnosti nositelja ekonomske politike zemalja članica. Ako ciklusi nisu sinkronizirani među zemljama, postaje vrlo teško voditi monetarnu politiku koja je prikladna za sve zemlje članice te troškovi jedinstvene valute postaju preveliki (Gächter i dr., 2012).

Pad u usklađenosti nakon financijske krize iz 2008. uočavaju Gächter i dr. (2012) i Belke i dr. (2017). Potonji, primjećuju pad sinkronizacije ekonomske aktivnosti između perifernih i središnjih zemalja nakon financijske krize naspram razdoblja prije krize. No kada uzimaju u obzir cijelo promatrano razdoblje, primjećuju čvrstu povezanost poslovnih ciklusa zemalja s onim agregiranog EA-12 područja. Arčabić i Škrinjaric (2021) pokazuju da je usklađenost poslovnih ciklusa pozitivno povezana s prelijevanjima makroekonomskih šokova. Krize koje su pogodile Europsku uniju od 2008. naovamo uzrokovale su prelijevanja simetričnih šokova, što je pogodovalo usklađenosti većine, ali ne svih zemalja članica. Dok Giannone i dr. (2010) zaključuju kako prihvaćanje jedinstvene valute nije

dovelo do promjena u korelaciji ni kod središnjih ni kod perifernih zemalja, Furceri i Karras (2008) primjećuju snažniju korelaciju s EMU kod Njemačke, Francuske, Italije i Nizozemske, nakon prihvatanja eura. U skladu s time, Darvas i Szapáry (2008) potvrđuju visoke razine usklađenosti poslovnih ciklusa središnjih zemalja članica s onim europodručja, dok periferne zemlje ipak pokazuju manju korelaciju, no vidljiva je tendencija postizanja razina središnjih zemalja.

Što se tiče Hrvatske, Arčabić (2018) zaključuje kako bi troškovi ulaska u monetarnu uniju trebali biti relativno niski s obzirom na umjerenu do snažnu sinkroniziranost s poslovnim ciklusima u EU od 2004. godine nadalje, a Arčabić (2011) pokazuje slične rezultate i za ranije razdoblje. Kotarac i dr. (2017) navode da je međusobna razina usklađenosti ciklusa i korelacije ekonomskih šokova Hrvatske i centralnih gospodarstva eurozone visoka. Također, primjećuju veću sinkronizaciju sa zemljama jezgre nego s rubnim članicama Europske unije. Sorić i dr. (2021) za mjerenje usklađenosti zemalja članica s agregatnim ciklusom EA-19 ili EA-11 koriste pomičnu korelaciju. Navedena mjera ukazuje na srednje do jaku povezanost s ciklusima EA-11 tijekom cijeloga promatranog razdoblja, no povezanost je izraženija tijekom razdoblja recesija.

Literatura o monetarnom pravilu započela je s Taylorovim radom (1993). Taylor (1993) je iznio prijedlog jednostavnoga monetarnog pravila, pomoću kojeg se može opisati politika FED-a tijekom povijesti. Najveću pažnju privukla je jednostavna algebarska formula koja opisuje formiranje nominalne kamatne stope s obzirom na stopu inflacije i jaz dohotka. Taylor je u svom originalnom pravilu fiksirao ravnotežnu realnu kamatnu stopu na 2%, a za inflaciju je koristio BDP deflator te je odredio ciljanu inflaciju na 2%. Nadalje, vremenom su se razvile alternative Taylorovu pravilu. Primjerice, moguće je uključiti zaglađivanje kamatne stope (inerciju), što predstavlja nominalnu kamatnu stopu s jednim pomakom unazad. Također, umjesto inflacije moguće je koristiti prognozirano inflaciju čime se u pravilo uključuju elementi pogleda u budućnost (primjerice Peersman i Smets, 1999; Gerdesmeier i Roffia, 2004; Sauer i Sturm, 2007).

Kao najbolju specifikaciju, Sauer i Sturm (2007) i Gardesmeier i Roffia (2004) preferiraju pravilo temeljeno na anketnim podacima, odnosno prognozama, jer sadrže aspekt budućnosti te su dostupni u stvarnom vremenu. Poput Peersman i Smets (1999), moguće je procijeniti agregatni model za odabrane zemlje članice te na temelju funkcije troškova procijeniti

optimalnu reakcijsku funkciju koju se uspoređuje s alternativama Taylorova pravila (TP) kao ograničena instrumentalna pravila. Usto, rezultati njihova istraživanja sugeriraju da bi jednostavno Taylorovo pravilo s relativno snažnijim odgovorom na jaz dohotka djelovalo stabilizirajuće na ekonomiju u slučaju makroekonomskih šokova. Gerlach i Schnabel (2000) usporedbom specifikacija sa zaglađivanjem kamatne stope, kratkoročnom kamatnom stopom u SAD-u, rast novca i promjenom u realnom tečaju EUR/USD, sugeriraju da jednostavno TP zadovoljavajuće objašnjava evoluciju EMU kamatne stope kroz vrijeme. Bhattarai i Carter (2018) linearnom regresijom procjenjuju originalno TP te ono sa zaglađivanjem kamatne stope. Originalno pravilo neadekvatno opisuje monetarnu politiku eurozone, dok s druge strane dodavanjem kamatne stope s pomakom se prikladnost modela značajno popravlja, što sugerira kako ECB postupno mijenja razinu kamatne stope, što dokazuje i Castelnovo (2003) u svom radu o "endogenoj postupnosti" monetarne politike.

3. METODOLOGIJA ISTRAŽIVANJA I PODACI

3.1. Podaci

U radu se proučava usklađenost poslovnih ciklusa zemalja članica Ekonomske i monetarne unije (ukupno 19 zemalja) s agregiranim područjem EA-19. Za analizu usklađenosti koriste se desezonirani kvartalni podaci o bruto domaćem proizvodu prikupljeni za zemlje članice EA-19 iz baze podataka Eurostat. Za sve zemlje (osim Malte i Nizozemske), podaci obuhvaćaju razdoblje od 1995:1 do 2021:1. Dok podaci za Nizozemsku obuhvaćaju razdoblje od 1996:1 do 2021:1, a za Maltu od 2000:1 do 2021:1. Monetarno, pravilo procjenjuje se za agregatno europsko područje. Podaci o nominalnoj kamatnoj stopi i o BDP-u preuzeti su sa statističke baze podataka Eurostat. Podaci o inflaciji, prognoziranoj i baznoj inflaciji preuzeti su iz baze podataka Europske središnje banke. Analiza obuhvaća razdoblje od 1999:1 do 2021:1.

3.2. Metodologija

Za analizu usklađenosti vremenske serije BDP-a razdvajaju se na cikličku i trend komponentu. Ciklička komponenta koja aproksimira poslovne cikluse izračunata je pomoću dvije metode: Hamiltonovim (2018) i Hodrick-

Prescott (1997) filterom. Hodrick-Prescott (HP) je procedura dekompozicije vremenske serije na trend i cikličku komponentu. Ciklička komponenta (c_t) predstavlja razliku između trenda (τ_t) i stvarne vrijednost serije (y_t):

$$c_t = y_t - \tau_t \quad (1)$$

Trend komponenta dobiva se minimiziranjem sljedećeg problema (Hodrick i Prescott, 1997.):

$$\min_{\tau} \left(\sum_{t=1}^T (y_t - \tau_t)^2 + \lambda \sum_{t=2}^{T-1} [(\tau_{t+1} - \tau_t) - (\tau_t - \tau_{t-1})]^2 \right) \quad (2)$$

Parametar zaglađivanja λ mora biti nenegativan te se za kvartalne podatke uobičajeno odabire $\lambda = 1600$, dok se za godišnje i mjesečne podatke koristi vrijednost od 100, odnosno 14.400.

Hamiltonov filter nastao je kao kritika Hodrick-Prescott filtera. Naime, Hamilton (2018) tvrdi da HP filter stvara prividne cikluse te da filtrirane serije na kraju uzorka previše odskoču od onih u sredini uzorka. Hamilton (2018) predlaže filter koji se temelji na autoregresivnom modelu i razlici između stvarne i procijenjene vrijednosti BDP-a u vremenu t i $t + h$. Za kvartalne podatke procjenjuje se sljedeća jednadžba:

$$y_{t+h} = \alpha_0 + \alpha_1 y_t + \alpha_2 y_{t-1} + \alpha_3 y_{t-2} + \alpha_4 y_{t-3} + c_t \quad (3)$$

Trend je razlika između stvarnog BDP-a i ciklusa, dok je ciklus jednak rezidualu regresijske jednadžbe (3). Također, prednost ove metode izdvajanja cikličkih fluktuacija je intuitivnost i jednostavnost te se može izračunati u bilo kojem statističkom softveru (Arčabić, 2018).

Nadalje, u radu se procjenjuju klasično Taylorovo pravilo i njegove alternative prema Knotek i dr. (2016). Taylorovo pravilo (1993) prikazuje formiranje nominalne kamatne stope u odnosu na jaz dohotka i inflacije te trenutačnu inflaciju:

$$i_t = r^* + \pi_t + 0,5(\pi_t - \pi^*) + 0,5(y_t - \tau_t) \quad (4)$$

U ovom pravilu, i_t predstavlja kamatnu stopu središnje banke u vremenu t , a varijabla r^* odnosi se na ravnotežnu realnu kamatnu stopu, što se u slučaju pravila može smatrati dugoročnom realnom kamatnom stopom. Razina inflacije je π_t , dok je $\pi_t - \pi^*$ jaz inflacije, odnosno razlika između stvarne i ciljane inflacije π^* . Jaz dohotka, $y_t - \tau_t$, procjenjuje u kojoj mjeri

trenutačna ekonomska aktivnost prelazi potencijalnu razinu u odabranom razdoblju.

Sljedeće pravilo je modifikacija originalnoga Taylorova pravila u kojem je parametar uz jaz dohotka jednak 1, umjesto 0,5, kao što je navedeno u prethodnom pravilu. Najveća razlika je u tome što se, umjesto trenutačne inflacije, uključuje bazna inflacija bez cijene energenata i hrane π_t^{Core} . Naime, koristi se kao mjera inflacije kako bi se izgladila volatilitnost uzrokovana promjenama cijena energenata i hrane:

$$i_t = r^* + \pi_t^{Core} + 0,5(\pi_t^{Core} - \pi^*) + (y_t - \tau_t) \quad (5)$$

U trećem pravilu, dodaje se inercija kako bi se prikazala tendencija kamatne stope da se ne prilagođava smjesta jazu dohotka i inflaciji:

$$i_t = \rho i_{t-1} + (1 - \rho)[r^* + \pi_t^{Core} + 0,5(\pi_t^{Core} - \pi^*) + (y_t - \tau_t)] \quad (6)$$

Koeficijent ρ predstavlja inerciju monetarnog pravila, a i_{t-1} je kamatna stopa s vremenskim pomakom, a u literaturi se još naziva zaglađivanje kamatne stope (npr. Peersman i Smets, 1999).

Posljednje, pravilo s očekivanjima uključuje prognozu inflacije za tri kvartala unaprijed π_{t+3}^F , što prikazuje tendenciju formiranja politike na temelju očekivanja. Preciznije rečeno, takva pravila objašnjavaju vremenski raskorak između trenutka donošenja mjera politike i njihovog djelovanja na ekonomiju:

$$i_t = r^* + \pi_{t+3}^F + 0,5(\pi_{t+3}^F - \pi^*) + (y_t - \tau_t) \quad (7)$$

4. ANALIZA USKLAĐENOSTI POSLOVNIH CIKLUSA I PRIMJENJIVOST MONETARNOG PRAVILA U ZEMLJAMA EUPODRUČJA


4.1. Analiza usklađenosti poslovnih ciklusa s europodručjem

Grafikon 1. pokazuje izračune poslovnih ciklusa u odabranim zemalja na temelju Hamiltonova (2018) i Hodrick i Prescott (1997) filtera. Vidljivo je da Hamiltonov filter ukazuje na veće oscilacije ciklusa BDP-a u odnosu na Hodrick-Prescott filter. Najveće razlike prisutne se u razdoblju financijske krize, tijekom kojeg Hamiltonov filter pokazuje dublju recesiju od Hodrick-Prescott filtera, odnosno veći pad u BDP-u. Također, u razdoblju nakon zadnjeg kvartala 2014. do trećeg kvartala 2016. godine, poslovni ciklusi


imaju različite predznake ovisno o metodi izračuna. U razdoblju recesije izazvane globalnom pandemijom, ciklus poprima izrazito slične vrijednosti kod obje metode izdvajanja cikličke komponente.

Grafikon 1. Usporedba cikličke komponente Hodrick-Prescott i Hamiltonova filtera na primjeru odabranih zemalja


a) Eurozona




b) Njemačka



c) Grčka



d) Portugal



Izvor: izrada autora.

Na temelju cikličke komponente BDP-a, izračunava se jednostavna Pearsonova korelacija i petogodišnja centrirana pomična korelacija. Navedene korelacije daju uvid u razinu usklađenosti zemalja članica EMU i same eurozone. Što se tiče Pearsonove korelacije, za izdvojene cikluse

pomoću Hodrick-Prescott filtera razdoblje promatranja obuhvaća razdoblje od prvog kvartala 1995. do prvog kvartala 2021. godine, dok je kod pomične korelacije zbog pomičnog prozora od 5 godina, razdoblje promatranje od zadnjeg kvartala 1999. do prvog kvartala 2021. godine.

Tablica 1. Usporedba jednostavne korelacije poslovnih ciklusa dobivenih pomoću Hodrick-Prescott i Hamiltonova filtera

ZEMLJA	HAMILTON	HODRICK-PRESCOTT
Austrija	0,85	0,91
Belgija	0,88	0,91
Njemačka	0,86	0,92
Francuska	0,9	0,93
Italija	0,81	0,97
Luksemburg	0,71	0,70
Finska	0,73	0,71
Nizozemska	0,84	0,91
Portugal	0,81	0,88
Španjolska	0,87	0,93
Slovenija	0,82	0,88
Irska	0,45	0,5
Grčka	0,35	0,48
Estonija	0,53	0,5
Litva	0,46	0,44
Latvija	0,53	0,5
Cipar	0,69	0,75
Malta	0,66	0,71
Slovačka	0,55	0,63

Izvor: izrada autora.

Korelacija je nešto viša kod ciklusa izračunatih Hodrick-Prescott filterom u odnosu na Hamiltonov filter (Tablica 1.) osim u slučaju Litve, Latvije, Estonije i Luksemburga. U slučaju Italije i Grčke, razlika u korelaciji je najveća između dvije metode filtriranja. Kod Italije Hamiltonov filter pokazuje korelaciju od 0,81, a HP filter 0,97, dok je korelacija u slučaju Grčke 0,35 i 0,48. Dodatno, zanimljiv je rezultat što baltičke zemlje i


Luksemburg pokazuju veću korelaciju kod Hamiltonova filtera naspram Hodrick-Prescott filtera. Naime, razlike su prisutne zbog načina primjene Hamiltonova filtera s razdobljem pogleda unaprijed od dvije godine i četiri pomaka čime se dobivaju podaci o ciklusima od zadnjeg kvartala 1997. godine, dok su kod Hodrick-Prescott filtera podaci o ciklusima zemalja članica dostupni od prvog kvartala 1995. godine.

Gräbner i dr. (2020) u svom radu predlažu podjelu zemalja Europske unije u četiri grupe: centar (engl. *Core*), periferija, priključak (engl. *Catch-up*) i financije. U centralne zemlje spadaju Austrija, Belgija, Danska, Finska, Francuska, Njemačka i Švedska, koje imaju visoki BDP per capita, snažnu industrijsku proizvodnju, proizvodnju složenih proizvoda te relativno niske stope nezaposlenosti. Periferiju čine Cipar, Grčka, Italija, Portugal i Španjolska čije su zajedničke karakteristike: niži udio izvoza, visok državni dug, sklonost deficitu tekućeg računa platne bilance i relativno visoke razine nezaposlenosti. Ekonomije priključka imaju relativno niske nadnice i BDP per capita, visoki stupanj stranog vlasništva te manji sektor usluga i jaki proizvodni sektor. U zemlje s navedenim karakteristikama spadaju Bugarska, Češka, Rumunjska, Estonija, Litva, Latvija, Mađarska, Poljska, Slovenija i Slovačka. Posljednja grupa zemalja je financije (engl. *Finance*) u koju se svrstavaju Luksemburg, Irska, Nizozemska i Malta. Svojstva ovih zemalja su visoka razina zaduženosti privatnih tvrtki, visok udio financija u BDP-u, visoka razina direktnih stranih investicija i znatni prihodi od poreza na bogatstvo.

Uočljive su znatne sličnosti u kretanju pomične korelacije u centralnim zemljama eurozone (Grafikon 2.). Također, crveno osjenčana područja su razdoblja pada ekonomske aktivnosti. Od 1999:4 do 2007. godine vidljive su razlike u usklađenosti među članicama. Tijekom 2007. godine sve zemlje iz skupine konvergiraju s ciklusom EA-19 te tijekom i nakon globalne financijske krize. Razine usklađenosti su izrazito slične i visoke, u razdoblju nakon financijske krize od 2010:4 do 2012:1. Nakon tog razdoblja obilježenog visokom razinama korelacija ciklusa, počinje razdoblje pada usklađenosti sve do 2017:1. Ističe se Francuska čiji se ciklus u tom razdoblju kreće u suprotnom smjeru od onog eurozone. Naime, u 2017:1 BDP agregiranog europodručja raste, dok francusko gospodarstvo i dalje poprima negativne stope rasta. Ciklusi Njemačke i Finske divergiraju zbog bržeg rasta u usporedbi s eurozonom, dok s druge strane ciklus Austrije divergira zbog sporijeg oporavka gospodarstva. Belgija je iznadprosječno usklađena s ciklusom europodručja od 2008. godine do kraja promatranog

razdoblja. Tijekom globalne krize uzrokovane pandemijom COVID-19, zemlje centra (osim Finske) dostižu visoke razine usklađenosti prisutne nakon financijske krize zbog značajnog pada BDP-a koji je zahvatio sve zemlje podjednako. Iako je 2019. godina obilježena jakom povezanosti s cikličkim kretanjima eurozone za sve zemlje, moguće je primijetiti dosizanje još snažnije, praktički savršene, povezanosti tijekom koronakrize, pogotovo u 2020:2, uz iznimku Finske.

Grafikon 2. Usklađenost poslovnih ciklusa centralnih zemalja europskog područja (Belgija, Njemačka, Francuska, Austrija i Finska) s EA-19




Izvor: izrada autora.

Kod perifernih zemalja u razdoblju financijske krize postoje veće razlike u usklađenosti u usporedbi sa zemljama centra te su razine usklađenosti općenito volatilnije (Grafikon 3.). Jednako kao i kod zemalja centra, tijekom 2007. godine usklađenost s ciklusom eurozone postaje izrazito visoka. Iznimka je Grčka koja tijekom većine promatranog razdoblja poprima najniže vrijednosti korelacije. Financijska kriza drastično je pogodila grčku ekonomiju, zbog čega ciklus poprima negativne vrijednosti te do kraja 2011. godine grčki BDP pada za 11% (Gächter i dr., 2012). Od 2008:4 usklađenost ciklusa postupno se smanjuje sve do 2011:2, kada se ciklus Grčke počinje kretati u suprotnom smjeru od ostatka EA-19. Razlog tomu je

činjenica da se ostatak Europe počeo oporavljati od krize, dok je Grčka sve više osjećala posljedice dužničke krize (Gächter i dr., 2012). Međutim, kriza uzrokovana pandemijom uskladila je grčki poslovni ciklus s europodručjem te je Grčka dostigla najvišu razinu usklađenosti od financijske krize. Ciklus Italije ima najstabilniju i visoku razinu korelacije s ciklusom eurozone tijekom cijelog promatranog razdoblja. Više kolebanja prisutno je kod Portugala, Španjolske i Cipra sve do kraja 2017. godine, nakon čega se usklađenost stabilizira do kraja razdoblja. Kao i u prethodnoj skupini, u razdoblju netom prije koronakrize prisutna je visoka usklađenost kod svih zemalja, a pogotovo kod Portugala, Španjolske i Italije. U 2020:2 sve zemlje postižu izrazito snažnu povezanost s poslovnim ciklusom eurozone, no trebalo bi istaknuti Italiju i Španjolsku čija je korelacija gotovo savršena.

Grafikon 3. Usklađenost poslovnih ciklusa zemalja periferije europodručja (Grčka, Španjolska, Italija, Cipar i Portugal) s EA-19




Izvor: izrada autora.

Gospodarstva priključka pokazuju različite tendencije u usklađenosti s europodručjem (Grafikon 4.). U ovoj skupini također, primjetno je da sinkronizacija cikličkih kretanja od 2007. godine postiže više razine. Slovenija i Slovačka imaju izrazito stabilnu razinu usklađenosti od razdoblja prije globalne financijske krize nadalje. Suprotno, kod baltičkih zemalja

primjetno je kako usklađenost znatnije varira kroz vrijeme. Zanimljivi su rezultati tijekom dužničke krize. Naime, dužnička kriza je zakašnjelo djelovala na baltička gospodarstva zbog čega u prvoj polovici krize od 2012. do 2014. godine korelacija kreće padati. U drugoj polovici dužničke krize, EA-19 obilježavaju i dalje negativne, ali manje stope pada gospodarske aktivnosti. S druge strane, u baltičkim zemljama postoji ozbiljniji pad gospodarske aktivnosti, što je razlog nižih razina usklađenosti. U 2019. godini prisutne su visoke razine usklađenosti kod svih, ali Slovačka i Slovenija i dalje bilježe najsnažniju usklađenost. Tijekom koronakrize kod svih zemalja vidljivo je ujednačavanje i rast usklađenosti s eurozonom, zbog značajnog pada BDP-a u svim zemljama. Taj je obrazac jednak u svim skupinama zemalja.

Grafikon 4. Usklađenost poslovnih ciklusa zemalja priključka (Estonija, Litva, Latvija, Slovenija i Slovačka) s EA-19




Izvor: izrada autora.

Posljednja skupina su financije, u koju spadaju Irska, Luksemburg, Malta i Nizozemska (Grafikon 5.). Ova skupina ujedno bilježi i najveće oscilacije po pitanju usklađenosti poslovnih ciklusa. Ova skupina je ujedno i vrlo heterogena te su strukture gospodarstava prilično različite. Luksemburg i Malta su male države s fokusom na tek nekoliko djelatnosti, od kojih se izdvajaju financije. Nizozemska i Irska s druge strane imaju diverzificiranu

strukturu gospodarstva, pri čemu je irsko gospodarstvo značajno orijentirano na izvoz i trgovinu sa zemljama izvan Europske unije, prije svega Ujedinjeno Kraljevstvo i SAD. Sve članice iz skupine dostižu veće i ujednačene razine usklađenosti u razdoblju neposredno prije, tijekom i odmah nakon globalne financijske krize. U slučaju Nizozemske vidljivo je da je usklađenost stabilna i na otprilike istoj razini tijekom cijelog promatranog razdoblja, dok je kod ostatka zemalja vidljiva volatilnost razine usklađenosti tijekom analiziranog razdoblja. Malta od početka promatranog razdoblja do završetka dužničke krize, pokazuje niže razine usklađenosti s eurozonom, ali u razdoblju krize uzrokovane pandemijom COVID-19 sustiže razine usklađenosti drugih zemalja iz skupine. Nadalje, sinkronizacija cikličke komponente Luksemburga s onom eurozone je visoka do početka dužničke krize, nakon čega postupno pada do 2016:3. Razdoblje neposredno nakon, obilježeno je rastom usklađenosti, no dolazi do ponovnog pada te čak u zadnjem kvartalu 2019. postiže negativnu korelaciju. Nagli rast je vidljiv od nastanka pandemije koronavirusa u prvom kvartalu 2020. godine.

Grafikon 5. Usklađenost poslovnih ciklusa skupine financije (Malta, Luksemburg, Irska i Nizozemska) s EA-19



Izvor: izrada autora.

Iz analize pomične korelacije kroz vrijeme moguće je istaknuti određene obrasce kretanja usklađenosti između zemalja članica EMU i EA-19. Kod svih skupina zemalja, tijekom 2007. godine može se uočiti rast usklađenosti s eurozonom svih članica te međusobno ujednačavanje što se tiče korelacije. Taj porast usklađenosti je prije svega rezultat ubrzanog rasta koji je bio posljedica pregrijavanja gospodarstava netom prije globalne financijske krize. Tijekom i nakon financijske krize, korelacija upućuje na srednje do jaku povezanost u slučaju svih zemalja, izuzev Grčke. Nakon dužničke krize većina gospodarstava pokazuje tendenciju pada u povezanosti cikličkih kretanja. Uzrok tome je ozbiljnije usporavanje gospodarske aktivnosti naspram eurozone kod jednih, a kod drugih je razlog tomu slabiji utjecaj krize na ekonomiju. Oporavak nakon krize nije se odvijao jednakom brzinom kod svih zemalja te su zemlje centra tipično bile uspješnije od perifernih i zemalja priključka. U tom razdoblju javila se ideja o Europi s dvije brzine (engl. *Two-speed Europe*) koju je popularizirao Blanchard (2010). U razdoblju obilježenom pandemijom i posljedičnom krizom, visoka usklađenost s eurozonom je zajednička karakteristika svih zemalja, čak i Luksemburga i Irske koji su nedugo prije pojave koronavirusa imali negativnu korelaciju s agregiranim europodručjem. Iz navedenog može se zaključiti kako je utjecaj koronakrize podjednak na sve države članice, dok su posljedice dužničke krize bile heterogene. Stoga, može se zaključiti kako ekonomski šokovi potiču rast usklađenosti poslovnih ciklusa te su posljedične krize karakterizirane visokom usklađenošću, dok su faze ekspanzije obilježene slabijom povezanosti cikličkih kretanja. Prva skupina, odnosno centralne zemlje eurozone, tijekom većine razdoblja snose relativno manje troškove članstva u Ekonomskoj i monetarnoj uniji, s iznimkom razdoblja 2016:4 – 2017:2 izrazito niske prosječne usklađenosti, nekarakteristične za tu skupinu. Zemlje periferije EMU pokazuju nešto nižu prosječnu povezanost s ciklusima eurozone, zbog čega se može zaključiti da je cijena odustajanja od samostalne monetarne politike relativno veća kod ove skupina naspram zemalja centra. Usklađenost skupine priključka s cikličkim kretanjima EMU je manja i od skupine centralnih i perifernih zemalja. Preciznije rečeno, u usporedbi s navedenim grupama gospodarstva, grupa priključka, u relativnom smislu, snosi najveće troškove zajedničke monetarne politike na štetu vlastitih ekonomija. Međutim, uz iznimku baltičkih zemalja, razina usklađenosti je i dalje dovoljno visoka za zajedničku monetarnu politiku. Posljednja skupina financije pokazuje umjerenu sinkroniziranost poslovnih ciklusa, no naspram drugih skupina je

veza poprilično slabija, što čini trošak prihvatanja zajedničke kontracikličke monetarne politike najvećim u ovoj skupini. Također, mogu se izdvojiti Belgija, Nizozemska, Slovenija, Slovačka i Italija zbog izrazito stabilnih i visokih razina usklađenosti, od 2007. do kraja promatranog razdoblja. Prema tome, teret prihvatanja zajedničke valute je najmanji u slučaju navedenih zemlja. Rezultati i analiza upućuju na to da eurozona čini optimalno valutno područje, zbog toga što je u posljednjih 14 godina (osim razdoblja dužničke krize od polovice 2012. do 2016.) usklađenost ciklusa umjerena do jaka kod skoro svih zemalja. Potrebno je i dalje provoditi mjere usklađivanja gospodarstava te jačati kanale vanjske trgovine i financija kako bi gospodarstva bila što usklađenija te kako bi troškovi monetarne unije bili zanemarivi.

4.2. Primjenjivost monetarnog pravila u europodručju

U svom originalnom radu Taylor (1993) tvrdi da je ponder uz inflaciju jednak 1 te uz jaz dohotka 0,5. Međutim, rezultati u Tablici 2. pokazuju da je u originalnom Taylorovu pravilu samo inflacija značajna na razini od 1%, dok su jaz dohotka i konstanta statističke neznčajne. U prvom modelu koeficijent uz jaz dohotka poprima negativnu vrijednost, što je oprečno originalnom Taylorovu pravilu.

TP s baznom inflacijom pokazuje potpuno drugačije rezultate od originalnoga pravila. Reakcija središnje banke na baznu inflaciju je izrazito snažna, dok je u prvom modelu ipak nešto manja, iako su u oba modela varijable značajne. Nadalje, koeficijent uz jaz dohotka ima pozitivan predznak te je veći od 1, no nije statistički signifikantan. Inercijsko TP najbolje opisuje odnos između kamatne stope i jaza dohotka i inflacije. Međutim, u ovaj model uključena je kamatna stopa s jednim pomakom unatrag kako bi se uključio efekt inercije, koji objašnjava ponašanje kamatne stope koja se postupno prilagođava vrijednosti inflacije i jaza dohotka (Knotek i dr., 2016). U spomenutom modelu sve su varijable statističke značajne. Zanimljiv je rezultat da inflacija poprima negativnu vrijednost te se koeficijent uz jaz dohotka smanjuje, u usporedbi s drugim modelom, na 0,504. Model s pogledom u budućnost sadrži prognoziranu inflaciju s tri pomaka unaprijed, koja je statistički značajna. Također, koeficijent uz jaz dohotka je najveći u ovom modelu te je također signifikantan. Posljednji model umjesto inflacije obuhvaća jaz inflacije. Inflacija i konstanta su značajne, no jaz dohotka je statistički

nesignifikantan. Zaključno, od ovih pet odabranih modela, inercijsko pravilo najbolje objašnjava odnos između zavisne i nezavisnih varijabli, što dokazuje koeficijent determinacije od 0,970 te statistička značajnost svih regresora uključenih u model.

Tablica 2. Procijenjena monetarna pravila prema Knotek i dr. (2016)

	Zavisna varijabla:				
	Originalno TP	Bazna inflacija TP	i_t Inercijsko TP	TP s pogledom u budućnost	Jaz inflacije TP
π_t	1.140*** (0.173)				
π_t^{Core}		2.225*** (0.314)	-0.261*** (0.094)		
π_{t+3}^F				0.840*** (0.160)	
$\pi_t - \pi^*$					1.140*** (0.173)
$Y_t - Y^{trend}$	-0.297 (1.203)	1.542 (1.087)	0.504** (0.246)	2.068* (1.175)	-0.297 (1.203)
i_{t-1}			1.025*** (0.026)		
Konstanta	-0.421 (0.317)	-1.519*** (0.440)	0.270** (0.109)	0.099 (0.308)	1.858*** (0.159)
# promatranja	89	89	88	86	89
R ²	0.371	0.402	0.970	0.285	0.371
Korig. R ²	0.356	0.388	0.969	0.268	0.356
Std. greška reziduala	1.372 (df = 86)	1.338 (df = 86)	0.300 (df = 84)	1.456 (df = 83)	1.372 (df = 86)
F Statistika	25.347*** (df = 2; 86)	28.937*** (df = 2; 86)	918.692*** (df = 3; 84)	16.574*** (df = 2; 83)	25.347*** (df = 2; 86)

Napomena: * p<0.1, ** p<0.05, *** p<0.01

Izvor: izrada autora.

Zbog navedenih zaključaka, uključuje se inercija, odnosno kamatna stopa s pomakom unazad u sve prijašnje modele kako bi bilo moguće procijeniti koje od nezavisnih varijabli najbolje objašnjavaju vezu između kamatne stope, jaza dohotka i inflacije (Tablica 3.). U originalnom TP, dodavanjem kamatne stope s vremenskim pomakom parametar uz inflaciju se smanjuje te gubi signifikantnost, no ponder jaza dohotka poprima pozitivne vrijednosti. Vidljivo je kako u tom slučaju središnja banka relativno snažno odgovara na zaglađivanje kamatne stope, koja je značajna varijabla u modelu. Zanimljivo je kako u svakom od modela (osim s jazom inflacije) postoji barem jedan koeficijent koji ima negativan predznak, što je u suprotnosti s originalnim TP. Mogući razlog tomu je što je politika ECB-a od zadnjeg kvartala 2014. godine sve do danas, obilježena negativnim kamatnim stopama. Također, originalno TP sa zaglađivanjem kamatne stope se ne može, ni u ovom slučaju, smatrati najprikladnijim. Najsnažniji efekt jaza dohotka na kamatnu stopu prisutan je u inercijskom modelu. Ponder uz zaglađivanje kamatne stope je najveći i značajan je u svakom modelu. Usporedbom odabranih modela na temelju signifikantnosti varijabli, koeficijenta linearne determinacije, rezidualnim odstupanjima i F-testu, vidljivo je kako inercijski model s baznom inflacijom najbolje odgovara odabranom uzorku.

Tablica 3. Procijenjena pravila s dodanom inercijom


	Zavisna varijabla:			
	Originalno TP s inercijom	Inercijsko TP	i_t TP s pogledom u budućnost i inercijom	Jaz inflacije TP s inercijom
π_t	0.076 (0.048)			
π_t^{Core}		-0.261*** (0.094)		
π_{t+3}^F			0.116*** (0.037)	
$\pi_t - \pi^*$				0.076 (0.048)
$Y_t - Y^{trend}$	0.310 (0.271)	0.504** (0.246)	0.451* (0.247)	0.310 (0.271)
i_{t-1}	0.955*** (0.024)	1.025*** (0.026)	0.946*** (0.022)	0.955*** (0.024)
Konstanta	-0.100 (0.072)	0.270** (0.109)	-0.155** (0.064)	0.053 (0.058)
# promatranja	88	88	85	88
R ²	0.969	0.970	0.970	0.969
Korig. R ²	0.968	0.969	0.969	0.968
Std. greška reziduala	0.308 (df = 84)	0.300 (df = 84)	0.301 (df = 81)	0.308 (df = 84)
F Statistika	865.566*** (df = 3; 84)	918.692*** (df = 3; 84)	870.674*** (df = 3; 81)	865.566*** (df = 3; 84)
Napomena:	*p<0.1, **p<0.05, ***p<0.01			

Izvor: izrada autora.

Inercijsko pravilo, kako je vidljivo na Grafikonu 6., najbolje opisuje ponašanje kamatne stope (Eonia). Naime, od 1999. do 2003. godine prema svim ostalim pravilima (osim inercijskog) kamatna stopa je trebala biti viša nego što je bila, pogotovo u razdoblju karakteriziranom niskom ili negativnom kamatnom stopom. Od 2004. do 2006. godine su procijenjena kamatna stopa i EONIA podjednakih razina. Nakon tog razdoblja, ponovno


se mogu primijetiti razlike u procijenjenim kamatnim stopama te se opet preklapaju tijekom kratkog razdoblja u 2014. godini. Od zadnjeg kvartala 2014. godine do danas, kamatna stopa poprima negativne vrijednosti. Prema svim modelima, osim inercijskog, procijenjena kamatna stopa trebala bi biti pozitivna, odnosno između 1 do 2%. Do ponovnog, kratkoročnog preklapanja procjena modela, dolazi od drugog do četvrtog kvartala 2020. godine, obilježeno koronakrizom.

Grafikon 6. Nominalna kamatna stopa i procjene prema pravilima iz Knotek i dr. (2016)



Izvor: izrada autora.

Promatrajući Grafikon 7., moguće je primijetiti kako dodavanjem kamatne stope s vremenskim pomakom (i_{t-1}), odnosno zaglađivanja, svi modeli značajno bolje opisuju ponašanje stvarne kamatne stope (EONIA). No na temelju regresijske analize inercijsko pravilo s baznom inflacijom ocijenjeno je kao najprikladnije za monetarnu politiku eurozone.

Grafikon 7. Procijenjena pravila s dodanom inercijom

Izvor: izrada autora.

Zaključno, dokazana je tendencija Europske središnje banke da mijenja kamatnu stopu postupno prema ciljanom smjeru. Negativne kamatne stope, koje su karakteristične za monetarnu politiku nakon globalne financijske krize, rezultiraju negativnim predznacima u određenim modelima. No i sam Taylor (1993) monetarna pravila zamišlja kao smjernicu za nositelje monetarne politike, u koje je moguće uključiti razne informacijske varijable. Originalno Taylorovo pravilo ne odgovara empirijskim podacima u ovome istraživanju, ali je koristan alat za nositelje ekonomske politike koji može poslužiti kao mjerilo pri donošenju odluka. Nadalje, pravilo s dodatkom kamatne stope s vremenskim pomakom može se primijeniti za opisivanje politike ECB-a, kao i sva razmatrana pravila sa zaglađivanjem. U ovom radu, analizom obuhvaćenim podacima najbolje pristaje model s baznom inflacijom koja ne uključuje promjene cijena energenata i hrane. Kada bi se upotrebljavala pravila sa zaglađivanjem kamatne stope, kao dodatnom

informacijskom varijablom, tada se monetarna politika ECB-a ne bi pretjerano razlikovala od one u prošlosti. Naspram diskrecijske politike, pravila poput Taylorova pružaju vremensku konzistentnost (Buol i Vaughan, 2003).

5. ZAKLJUČAK

U radu se analizira usklađenost poslovnih ciklusa zemalja članice EMU i agregiranog europodručja te procjenjuje primjenjivost monetarnog pravila na eurozonu. U prvom dijelu, ispituje se usklađenost poslovnih ciklusa petogodišnjim centriranim pomičnim koeficijentom korelacije. Poslovni ciklusi se aproksimiraju Hodrick-Prescott i Hamiltonovim filterom za izdvajanje cikličke komponente. U drugom dijelu, analizira se prikladnost monetarnog pravila za europodručje. Zbog njihove jednostavnosti i mogućnosti prilagođavanja, smatraju se korisnom oglednom vrijednosti s kojom je moguće uspoređivati nominalnu kamatnu stopu. Prema radu Knotek i dr. (2016) linearnom regresijom procjenjuju se originalno Taylorovo pravilo i tri inačice istog. Zbog rezultata analize, dodatno se procjenjuju pravila s dodatkom zaglađivanja kamatne stope.

Rezultati analize usklađenosti između odabranih zemalja i europodručja pokazuju da postoji jaka i pozitivna veza u razdoblju financijske i koronakrize. Suprotno, dužnička kriza uzrokovana visokom zaduženošću zemalja rezultira heterogenim tendencijama kretanja korelacije. Upravo ta heterogenost u različitim grupama zemalja u vrijeme dužničke krize predstavlja najveće ograničenje te najveću prijetnju zajedničke valute. Ukupne prednosti članstva u europodručju mogu se značajno smanjiti u vremenima krize kada je stabilizacijska uloga monetarne politike i najvažnija. U literaturi je pokazano da prelijevanja makroekonomskih šokova povećavaju usklađenost poslovnih ciklusa, ali Arčabić i Škrinjarčić (2021) naglašavaju da to pravilo ne vrijedi za neke periferne zemlje poput Grčke, Španjolske, Italije, Portugala, Mađarske i Estonije. Ipak, ako se uzima u obzir nedavno razdoblje, Ekonomska i monetarna unija može se smatrati optimalnim valutnim područjem zbog visoke usklađenosti svih zemalja članica (osim Irske) s cikličkim kretanjima europodručja.

Na temelju Gäbner i dr. (2020) zemlje su grupirane u četiri grupe, kako bi se moglo uvidjeti postoje li sličnosti u kretanju usklađenosti među zemljama sličnih obilježja. Uočljive su podudarnosti u kretanju i vrijednosti korelacije

kroz vrijeme u grupama, no ponajmanje u grupi financije koju čine Irska, Malta, Luksemburg i Nizozemska. Također, prisutna je volatilnost usklađenosti kod većine zemalja s iznimkom Italije, Slovenije, Nizozemske, Slovačke i Belgije koje nakon razdoblja pregrijavanja ekonomije u 2007. godini imaju visoku i stabilnu korelaciju do kraja promatranog razdoblja, čime se može zaključiti kako od svih zemalja snose najmanje troškove članstva. Rezultati usklađenosti kroz vrijeme nalažu kako centralne zemlje eurozone, u prosjeku, snose relativno najmanje troškove od sve četiri skupine.

Nadalje, procjena primjenjivosti monetarnih pravila temelji se na originalnom Taylorovu pravilu, pravilu s baznom inflacijom, inercijskom pravilu, pravilu s pogledom u budućnost i s jazom inflacije umjesto trenutne inflacije. Rezultati regresijske analize odabranih specifikacija Taylorova pravila pokazuju kako je zaglađivanje kamatne stope ključna varijabla za opis monetarne politike ECB-a. Naime, inercijsko pravilo uključuje kamatnu stopu s vremenskim pomakom koja predočava postupnost, karakterističnu za monetarnu politiku u eurozoni. Također, kada bi središnja banka određivala kamatnu stopu prema inercijskom pravilu, ne bi previše odstupala od monetarne politike u prošlosti. Stoga, nalazi ovog rada upućuju na to kako se Europska središnja banka koristi monetarnim pravilom pri vođenju monetarne politike, dok su diskrecijske odluke manje zastupljene.

LITERATURA

Arčabić, V. (2011). Usklađenost poslovnih ciklusa Republike Hrvatske sa zemljama Europske unije. *Zbornik Ekonomskog fakulteta u Zagrebu*, 9(1), 127-144.

Arčabić, V. (2018). Hrvatska na putu u eurozonu: analiza poslovnih ciklusa. *Zbornik radova znanstvenog skupa: Modeli razvoja hrvatskog gospodarstva, Zagreb: Ekonomski fakultet*, 157-176.

Arčabić, V., & Škrinjarić, T. (2021). Sharing is Caring: Spillovers and Synchronization of Business Cycles in the European Union. *Economic Modelling*, 96, 25-39.

Belke, A., Domnick, C., & Gros, D. (2017). Business Cycle Synchronization in the EMU: Core vs. Periphery. *Open Economies Review*, 28(5), 863-892.

Bhattarai, K., & Carter, M. (2018). An Empirical Analysis of the Taylor Rule and Its Application to Monetary Policy: A Case for the United Kingdom and Euro Area. *Asian Journal of Economics and Empirical Research*, 5(2), 173-182.

Blanchard, O. (2010). Interview. IMF Survey: Two-Speed Recovery to Extend into 2011, Says IMF. In: International Monetary Fund, December 30, 2010. Available at: <<https://www.imf.org/en/News/Articles/2015/09/28/04/53/sonew123010a>>.

Buol, J. J., & Vaughan, M. D. (2003). Rules vs. Discretion: the Wrong Choice Could Open the Floodgates. *The Regional Economist*, (Jan), 10-11.

Castelnuovo, E. (2003). Taylor Rules, Omitted Variables, and Interest Rate Smoothing in the US. *Economics Letters*, 81(1), 55-59.

Darvas, Z., & Szapáry, G. (2008). Business Cycle Synchronization in the Enlarged EU. *Open Economies Review*, 19(1), 1-19.

European Central Bank [online]. Dostupno na: <https://sdw.ecb.europa.eu/> [5. srpnja 2020.]

Eurostat [online]. Dostupno na: <https://ec.europa.eu/eurostat> [5. srpnja 2020.]

Furceri, D., & Karras, G. (2008). Business-Cycle Synchronization in the EMU. *Applied Economics*, 40(12), 1491-1501.

- Gerdemeier, D., & Roffia, B. (2004). Taylor Rules for the Euro Area: the Issue of Real-Time Data.
- Gächter, M., Riedl, A., & Ritzberger-Grünwald, D. (2012). Business Cycle Synchronization in the Euro Area and the Impact of the Financial Crisis. *Monetary Policy & the Economy*, 2(12), 33-60.
- Gerlach, S., & Schnabel, G. (2000). The Taylor Rule and Interest Rates in the EMU area. *Economics Letters*, 67(2), 165-171.
- Giannone, D., Lenza, M., & Reichlin, L. (2010). 4. *Business Cycles in the Euro Area* (pp. 141-168). University of Chicago Press.
- Gräbner, C., & Hafele, J. (2020). *The Emergence of Core-Periphery Structures in the European Union: A Complexity Perspective* (No. 6). ZOE Discussion Papers.
- Hamilton, J. D. (2018). Why You Should Never Use the Hodrick-Prescott Filter. *Review of Economics and Statistics*, 100(5), 831-843.
- Hodrick, R. J., & Prescott, E. C. (1997). Postwar US Business Cycles: an Empirical Investigation. *Journal of Money, Credit and Banking*, 1-16.
- Kenen, P. (1969). The Theory of Optimum Currency Areas: An Electic View. U: Mundell, R. i Swoboda, A., ur. *Monetary Problems of International Economy*. Chicago. The University of Chicago Press, str. 41-60.
- Knotek II, E. S., Verbrugge, R. J., Garciga, C., Treanor, C., & Zaman, S. (2016). Federal Funds Rates Based on Seven Simple Monetary Policy Rules. *Economic Commentary*, (2016-07).
- Kotarac, K., Kunovac, D., & Ravnik, R. (2017). *Coherence of Business Cycles and Economic Shocks Between Croatia and Euro Area Member States* (No. 53).
- McKinnon, R. I. (1963). Optimum Currency Areas. *The American Economic Review*, 53(4), 717-725.
- Mundell, R. A. (1961). A Theory of Optimum Currency areas. *The American Economic Review*, 51(4), 657-665.
- Peersman, G., & Smets, F. (1999). The Taylor Rule: A Useful Monetary Policy Benchmark for the Euro Area?. *International Finance*, 2(1), 85-116.

Sauer, S., & Sturm, J. E. (2007). Using Taylor Rules to Understand European Central Bank Monetary Policy. *German Economic Review*, 8(3), 375-398.

Sorić, P., Lolić, I., & Logarušić, M. (2021). On the Behavioral Antecedents of Business Cycle Coherence in the Euro Area. *EFZG Working Paper Series*, 2021(04), 1-28.

Taylor, J. B. (1993, December). Discretion Versus Policy Rules in Practice. In *Carnegie-Rochester Conference Series on Public Policy* (Vol. 39, pp. 195-214). North-Holland.

IS EUROZONE AN OPTIMAL CURRENCY AREA? BUSINESS CYCLE SYNCHRONIZATION ANALYSIS

Abstract

The paper analyzes business cycles synchronization among the Economic and Monetary Union Member States within the optimal currency area theory. It also examines just how applicable the monetary rule to euro area's monetary policy is. Business cycle synchronization suggests that the Member States are exposed to similar shocks, and therefore the common monetary policy of the European Central Bank does not create additional costs. Otherwise, low business cycle synchronization would suggest asymmetric shocks that require different economic policy responses. In that case, the common monetary policy would be costly to certain Member States. The analysis shows an increase in business cycle synchronization in all countries during the financial and coronavirus crisis. From 2007 onwards, most countries have strongly been correlated with the business cycle of the Eurozone, except during the period of the Sovereign debt crisis. The Sovereign debt crisis has so far presented the biggest challenge to the Eurozone, as certain peripheral countries were left without additional stabilization tools. Therefore, the Eurozone is the optimal currency area, and the benefits of the membership outweigh the costs. Regarding monetary rule, the results show that the European Central Bank's policy can be described by a rule with a lagged interest rate. On the other hand, the original Taylor rule is not suitable for describing the interest rate in the euro area.

Keywords: Taylor rule, business cycle synchronization, interest rate smoothing.

JEL klasifikacija: Q57, E11
Pregledni rad

FINANCIRANJE TRANZICIJE NA KRUŽNO GOSPODARSTVO

Zvonimira Šverko Grdić*

SAŽETAK

Zbog postojećega neodrživog linearnog načina proizvodnje javlja se potreba za uvođenjem modela kružnoga gospodarstva koji omogućuje ekonomski rast i blagostanje, a skladu je sa zaštitom okoliša i održivim razvojem. Ekonomski poremećaji uzrokovani pandemijom u 2020. godini intenzivirali su promišljanja o hitnijem prelasku na koncept održive potrošnje i održive proizvodnje, što je usko vezano uz pojam kružnoga gospodarstva. Za tranziciju je, među ostalim važnim elementima, potrebno osigurati financijska sredstva koja će omogućiti brži i jednostavniji prijelaz na novi način privređivanja. Pritom je osiguranje dostatnih financijskih sredstava ključno za uvođenje kružnoga gospodarstva, a ovisno o njihovoj količini, zavisit će i uspješnost implementacije.

Cilj rada je istaknuti važnost implementiranja koncepta kružnoga gospodarstva u ekonomiju kao i osiguranja dovoljnih financijskih sredstava u cilju osiguranja transformacije. U tom cilju u radu se analiziraju mogućnosti financiranja tranzicije putem postojećih fondova i ostalih izvora novčanih sredstava uz pomoć kojih se može uspješno i u potpunosti realizirati koncept kružnoga gospodarstva na razini Europske unije, pa time i Republike Hrvatske. Znanstveni doprinos rada ogleda se u prikazanom teorijskom konceptu vezanom uz pojam kružnoga gospodarstva, u prikazima napretka implementacije ovoga koncepta u ekonomijama Europske unije te u prikazu mogućnosti financiranja putem kojih bi se tranzicija mogla ubrzati.

* Izv. prof. dr. sc. Zvonimira Šverko Grdić, Fakultet za menadžment u turizmu i ugostiteljstvu, Opatija (e-mail: zgrdic@fthm.hr).

Rezultati rada ukazuju da će za tranziciju na kružno gospodarstvo biti potrebna značajna financijska sredstva koja su na raspolaganju putem različitih fondova Europske unije. Rad otvara mogućnost daljnjeg istraživanja ove tematike u smislu iskorištenosti financijskih sredstava i procesa uspješnosti implementacije ovog načina proizvodnje u gospodarstvo.

Ključne riječi: kružno gospodarstvo, financiranje, održivost, gospodarski razvoj.

1. UVODNA RAZMATRANJA

U kružnom gospodarstvu stvaranje otpada svodi se na minimalnu razinu uz pomoć pažljivog dizajniranja novog proizvoda i industrijskog procesa u kojem materijali neprestano cirkuliraju u zatvorenom krugu (Fischer i Pascucci, 2017). Primjena koncepta kružnoga gospodarstva potiče zaštitu okoliša i društveno blagostanje (Jawahir i Bradley, 2016), a s druge strane omogućava ekonomski rast koji je u skladu s održivim razvojem. Kružno gospodarstvo može umanjiti uništavanje okoliša u cjelokupnom sustavu, ali i povećati stvaranje novih dodanih vrijednosti. Ono svoje temelje pohranjuje u prirodi i prirodnim procesima u kojima otpad kao kategorija ne postoji. Stvaranje i osmišljavanje kružnoga gospodarstva u modernim društvima postaje imperativ budući da omogućava ponovno korištenje/recikliranje proizvoda, čuvanje prirodne regenerativne osnovice okoliša i stvaranje novih radnih mjesta, a sve uz generiranje dodatnih financijskih sredstava. Sadašnji linearni način proizvodnje u svim proizvodnim fazama koristi energiju te se temelji na zakonitosti "izvadi – proizvedi – koristi – odbaci" te predstavlja neodrživi način proizvodnje. S druge strane kružno gospodarstvo omogućava funkcioniranje ekonomskog sustava u kojem kruže sirovine i pretvaraju se iz jednog oblika u drugi te se ne stvara ili se pak stvara minimalna količina otpada. Ideja o konceptu kružnoga gospodarstva razvijala se kao posljedica shvaćanja negativnih utjecaja na okoliš trenutnog, linearnog načina proizvodnje.

Financiranje tranzicije nije jednostavan i jeftin proces te je iz tog razloga potrebno intenzivirati financiranje onih projekata koji u sebi implementiraju koncept kružnoga gospodarstva. U posljednje vrijeme na raspolaganju postoje brojni izvori financiranja kojima se zainteresirani dionici mogu financirati. Osim dostupnih izvora financiranja, ovi se projekti mogu poticati različitim poreznim subvencijama poput umanjivanja poreza na

dodanu vrijednost, uvođenja poreza na plastiku i ekstrakciju sirovina, prebacivanja poreznog opterećenja s rada ili obrazovanja na materijalne inpute i slično.

Cilj rada je istaknuti važnost implementiranja koncepta kružnoga gospodarstva u ekonomiju kao i osiguranja dovoljnih financijskih sredstava u cilju osiguranja transformacije. U tom cilju u radu se analiziraju mogućnosti financiranja tranzicije putem postojećih fondova i ostalih izvora novčanih sredstava uz pomoć kojih se može uspješno i u potpunosti realizirati koncept kružnoga gospodarstva na razini Europske unije, pa time i Republike Hrvatske.

Nakon uvodnih razmatranja u drugom dijelu prikazuje se pregled literature vezan uz kružno gospodarstvo. U trećem poglavlju daje se pregled indikatora putem kojih se prati razvoj kružnoga gospodarstva, ali i konkretno ostvareni rezultati na razini Europske unije. U četvrtom poglavlju daje se pregled mogućih izvora financiranja, mogućih modela razvoja kao i poreznih poticaja putem kojih se može intenzivirati proces prelaska s linearnog na kružni model privređivanja. Rad završava zaključnim razmišljanjima.

2. TEORIJSKE ODREDNICE KONCEPTA KRUŽNOGA GOSPODARSTVA

Brzi tehnološki razvoj, industrijalizacija i urbanizacija vode do povećanja zagađenja i povećane razine potrošnje proizvoda, a slijedom toga i do povećane razine proizvodnje otpada. Tijekom posljednjih desetljeća ovaj oblik razvoja rezultirao je mnogim negativnim posljedicama na okoliš. Danas su očuvanje okoliša i smanjenje stvaranja otpada veoma važna pitanja. Tako mnoge zemlje i regije osmišljavaju zakone i propise u cilju smanjivanja negativnih utjecaja na okoliš uključujući procese koji osiguravaju smanjivanje količine proizvedenog otpada i procese recikliranja (Stankevićene, Nikanorova i Cera, 2020).

Pojam kružno gospodarstvo izučava se od 70-ih godina prošloga stoljeća. Važnija zapažanja dali su autori Pearce i Turner koji su izučavali utjecaj prirodnih resursa na ekonomski sustav (Ghisellini, Cialani i Ulgiati, 2016). Na njihova razmišljanja utjecao je autor Bouding's (1966) koji je izučavao zemlju kao zatvoren kružni sustav s ograničenim kapacitetom prilagodbe te

je iz te činjenice zaključio da bi ekonomija i okoliš trebali koegzistirati u ravnoteži (Geissdoerfer, Savaget, Bocken i Hultink, 2017). Autori Stahel i Reday (1976) naveli su određene značajke kružnoga gospodarstva s fokusom na industrijsku ekonomiju. Oni su zamislili ekonomiju kao zatvorenu petlju u kojoj kruže materijali, što omogućava: sprječavanje stvaranja otpada, otvaranje novih radnih mjesta, postizanje učinkovitosti resursa i dematerijalizaciju industrijske ekonomije. Autor Stahel (1982) naglasio je da vlasništvo prestaje biti norma i u skladu s time mijenjaju se modeli poslovanja na način da se naglasak stavlja na mogućnost korištenja proizvoda ili usluga. Taj način predstavlja najrelevantniji održivi model poslovanja koji omogućava industriji da profitira bez eksternalizacije troškova i rizika povezanih s otpadom (Geissdoerfer i sur., 2017). U samom početku koncept kružnoga gospodarstva uključivao je 3R princip (reduce, reuse, recycle), da bi sada uključivao 6R princip (reuse, recycle, redesign, remanufacture, reduce, recover) (Jawahir i Bradley, 2016).

Kružno gospodarstvo definira se na različite načine, a dvije najcitiranije definicije kružnoga gospodarstva su: "središte kružnoga gospodarstva je kružni (zatvoreni) protok materijala i sirovina te upotreba energije kroz više faza" (Franklin-Johnson, Figgie i Canning, 2016). Druga definicija je da je to "ekonomija utemeljena na spiralnoj petlji odnosno sustavu koji minimizira propadanje tvari, protoka energije i okoliša bez ograničavanja ekonomskog rasta ili društvenog i tehničkog napretka" (Geng, Zhu, Doberstein i Fujita, 2009). Ellen MacArthur Foundation (2013) definira kružno gospodarstvo kao "industrijsku ekonomiju koja je obnavljajuća ili regenerativna po dizajnu ili namjeni". Autor Webster (2017) kaže da "kružno gospodarstvo ima za cilj stvaranje proizvoda, komponenti i materijala koji će kroz cijelo vrijeme imati najvišu upotrebnu vrijednost".

Uvođenje kružnoga gospodarstva javilo se kao odgovor na potrebu suočavanja s nedostacima postojećega linearnog sustava gospodarenja. Nasuprot linearnom načinu proizvodnje, sustavi kružnoga gospodarstva zadržavaju dodanu vrijednost u proizvodima što je duže moguće i imaju cilj eliminirati stvaranje otpada. Ključna razlika između linearnog i kružnoga oblika gospodarenja prikazana je u tablici 1.


Tablica 1. Usporedba kružnog i linearnog modela

	Linearna ekonomija	Kružno gospodarstvo
Osnovno obilježje	Stvara otpad nakon proizvodnje i korištenja dobara	Prevenira stvaranje otpada kroz dijeljenje, ponovno korištenje, popravak i recikliranje
Model	Model uzmi – proizvedi – odloži	• Dizajniranje proizvodnje bez stvaranja otpada i zagađenja • Držanje proizvoda i materijala u konstantnom kružnom tijeku • Regeneriranje prirodnih sustava
Poslovni proces	• Od proizvodnje do korištenja • Od korištenja do stvaranja otpada • Od otpada do uništavanja otpada	• Od proizvodnje do otpada • Otpad se nakon toga reciklira i pretvara u sirovinu za daljnju proizvodnju
Inovacije s otpadom	Otpad se odlaže i ne služi niti jednoj svrsi	Otpad se ili reciklira, dijeli ili ponovno koristi kao sirovina
Utjecaj na okoliš	Oštećuje okoliš	Čuva okoliš
Utjecaj na zapošljavanje	Ne kreiraju se novi poslovi	Kreiraju se novi poslovi. Može voditi do kreiranja nove industrije kao npr. industrije recikliranja
Količina iskorištene energije	Koristi sve više resursa i energije za proizvodnju novih proizvoda	Koriste manju količinu resursa i energije za proizvodnju novih dobara
Pokretači	Industrijska revolucija iz 1800-ih godina	Ciljevi održivog razvoja kreirani od Ujedinjenih naroda
Globalni ciljevi	Linearna ekonomija je široko rasprostranjen ekonomski model u mnogim zemljama	Kružno gospodarstvo je najmanje prihvaćeni ekonomski model u svijetu

Izvor: Ozili (2021). Circular Economy, Banks, and Other Financial Institutions: What's in It for Them?. Circular Economy and Sustainability (2021), <https://doi.org/10.1007/s43615-021-00043-y>

Kružno gospodarstvo počiva na shvaćanju da je otpad "hrana", što znači da svi materijali i proizvodi koji su se iskoristili i koji su došli u krajnju točku svojeg životnog vijeka mogu biti ponovno upotrijebljeni kao inputi za proizvodnju novih proizvoda (Tukker, 2015; Van Weelden, Muggie i Bakker, 2016). Kružno gospodarstvo bazira se na tri glavna načela, što prikazuje shema 1.

Shema 1. Načela kruznoga gospodarstva



Izvor: Tišma, Boromisa, Funduk i Čermak (2017). Okolišne politike i razvojne teme. Alineja, Zagreb, Hrvatska.

Koncept kruznoga gospodarstva uključuje sistemske promjene koje se baziraju na inovacijama i upotrebi novih tehnoloških sustava, ali isto tako i promjeni u sagledavanju/vođenju politike, društva, poslovnih modela i načina financiranja (Domenech i Bahn-Walkowiak, 2019). Ideja je kreirati regenerativan sustav gdje proizvodi, komponente i materijali održavaju njihovu najveću vrijednost što duže a resursi se jednostavno pretvaraju i ponovno integriraju u ekonomiju (Webster, 2017).

Koristi povezane s novim poslovnim modelom, kružnim gospodarstvom, uistinu su velike. Tako se procjenjuje da se povećanjem efikasnosti u korištenju resursa može osigurati ušteda sirovina u regiji u iznosu od 17 do 24% te godišnja ušteda troškova u iznosu od 630 milijuna EUR u Europi (Korhonen, Honkasalo i Seppala, 2018). Procjenjuje se da bi primjena koncepta kruznoga gospodarstva mogla povećati bruto domaći proizvod (BDP) Europske unije za dodatnih 0,5% i kreirati oko 700.000 novih radnih mjesta do 2030. godine (EU, 2020).

Iako se ideja o uvođenju koncepta kružnoga gospodarstva široko koristi u dokumentima i zakonodavstvu Europske unije, procjena napretka je različita ovisno o autorima (EASAC 2016; Haupt, Vandenbo i Hellweg, 2016; Kovanda 2014; Hashimoto, Tanikawa i Moriguchi, 2009; Yuan, Bi i Moriguchi, 2006). Većina istraživanja o napretku implementacije koncepta kružnoga gospodarstva bila je usredotočena na pojedinačne proizvode ili određene dijelove proizvodnog procesa pa su se sukladno tome formirala i mišljenja o mogućnosti napretka (Huysman, Schaepmeester, Ragaert, Dewulf i Meester, 2017). Za neke elemente proizvodnog ciklusa posljednjih godina baza znanja se doista poboljšala (BIO by Deloitte, 2015; Cullen i Allwood, 2013; Graedel, Harper, Nassarm i Reck, 2015; Reck i Graedel, 2012; Wang, Muller i Greadel, 2007), no dosta je istražena i mogućnost implementacije koncepta kružnoga gospodarstva u pojedinačnom poduzeću ili industriji (Pauliuk, Wang i Muller, 2012; Lieder i Rashid, 2016). Međutim, sveobuhvatne procjene kružnosti na nacionalnoj ili makrorazini, vrlo su rijetke (Nuss, Blengini, Hass, Mayer, Nita i Pennington, 2017; Hass, Krausmann, Wiedenhofer i Heinz, 2015; Hashimoto, Moriguchi, Saito i Ono, 2004).

Europska unija čini kontinuirane napore za transformaciju gospodarstva Europske unije (EU 27) na kružno gospodarstvo koje će imati za cilj postizanje veće održivosti. Europska komisija usvojila je niz mjera koje se odnose na kružno gospodarstvo poput: zabrane korištenja jednokratne plastike; poboljšanog zakonodavstva o sprječavanju nastanka otpada ili kritičnih sirovina (European Commission, 2019); poboljšanog praćenja indikatora kružnoga gospodarstva u cijeloj Europskoj uniji (EU 28) (Mayer, Haas, Wiedenhofer, Krausmann, Nuss i Blengini, 2019). Ključni elementi revidiranih prijedloga za gospodarenje otpadom prikazuju se u tablici 2.

Tablica 2. Ključni elementi revidiranih prijedloga gospodarenja otpadom u Europskoj uniji

Recikliranje i ponovno korištenje	Odlaganje
Zajednički cilj Europske unije je recikliranje i ponovna uporaba komunalnog otpada u 2030. godini na 60% i 2035. godine na 65%.	Obvezujući cilj smanjenja odlaganja otpada na odlagališta na najviše 10 % komunalnog otpada do 2030.
Pojednostavnjene i poboljšane definicije i usklađene metode izračuna stopa recikliranja u cijeloj Europskoj uniji.	Zabrana odlaganja odvojeno prikupljenog otpada (osim određenog opasnog otpada i zaostalog otpada).
Konkretna mjera za promicanje ponovne uporabe proizvoda i poticanje industrijske simbioze (pretvaranje nusproizvoda jedne industrije u sirovinu druge industrije).	Promicanje ekonomskih instrumenata za obeshrabrivanje odlaganja otpada (naknade za odlaganje otpada).
Ekonomski poticaji za proizvođače u cilju stavljanja na tržište zelenih proizvoda. Isto tako potrebno je podržavati programe uporabe i recikliranja (npr. za ambalažu, baterije, električnu i elektroničku opremu, vozila).	

Izvor: McDowall, Geng, Huang, Baretekova, Lbeischwitz, Turkeli, Kemp i Domenech, (2017). Circular Economy Policies in China and Europe. *Journal of Industrial Ecology*, 21(3), 651-661. <https://doi.org/10.1111/jiec.12597> i Andabaka, Beg i Gelo (2018). Challenges of circular economy in Croatia. *International Journal of Multidisciplinary Business Science*, 4, 115–126; Waste framework Directive, https://ec.europa.eu/environment/topics/waste-and-recycling/waste-framework-directive_en

U Republici Hrvatskoj tema kružnoga gospodarstva još je relativno nova, no veoma aktualna. Autori Ribić, Voća i Ilakovac (2017) u svojem radu govore o načinima gospodarenja otpadom u glavnom gradu Republike Hrvatske kao i o nužnosti uvođenja koncepta kružnoga gospodarstva. Autori Car i Jelavić (2016) govore o nužnosti prelaska s linearnog na kružno gospodarstvo. Autori Runko Luttemberger, Vujević, Šijeg i Gudelj (2015) u članku navode kružno gospodarstvo kao jedan od načina ostvarivanja resursne učinkovitosti. Autorica Andabaka (2018) u svojem radu ukazuje na moguće prednosti koje bi primjena načela kružnoga gospodarstva donijela hrvatskom gospodarstvu, ali i na postojeća ograničenja prilikom tranzicije na takav model gospodarstva. Autor Drljača (2015) ističe važnost tranzicije koncepta linearne u kružnu ekonomiju. Osim njih, autor Škrlec analizira temu kružnoga gospodarstva i na popularan način objašnjava primjenu i koristi apliciranja ovog načina proizvodnje i gospodarenja otpadom

(<http://www.davor-skrlec.eu>). Autorice Rudan, Krstinić Nižić i Šverko Grdić (2021) istraživale su primjenu koncepta kružnoga gospodarstva u turističkoj industriji.

Osim znanstvene zajednice koncept kružnoga gospodarstva pridobio je pažnju i kod dionika koji kreiraju zakone i donose odluke te na taj način utječu na vlade i međunarodne agencije u promoviranju novog koncepta funkcioniranja gospodarstva (Geisendorf i Pietrulla, 2018; Bocken, Olivetti, Cullen, Potting i Lifset, 2017).

3. REZULTATI PRIMJENE KONCEPTA KRUŽNOGA GOSPODARSTVA

Europska unija zauzima vodeće mjesto u odnosu na politike održivog razvoja i održivog korištenja resursa. No istodobno je ona jedna od većih potrošača resursa i proizvođača stakleničkih emisija (Haas, Krausmann, Wiedenhofer i Heinz, 2015). U cilju utvrđivanja napretka primjene koncepta kružnoga gospodarstva u ovom dijelu rada koriste se indikatori kružnoga gospodarstva koji se mogu naći u bazi Eurostata. Oni se mogu podijeliti u nekoliko grupa i podgrupa, i to:

- Proizvodnja i korištenje:
 - Samodostatnost sirovina za proizvodnju u Europskoj uniji;
 - Zelena javna nabava;
 - Proizvodnja komunalnog otpada;
 - Neiskorištena i odbačena hrana.
- Upravljanje otpadom:
 - Stope recikliranja (udio otpada koji se reciklira);
 - Vrste otpada (ambalažni otpad, biootpad, e-otpada itd.).
- Sekundarne sirovine:
 - Doprinos recikliranih materijala u potražnji sirovina;
 - Trgovina recikliranim sirovinama između država članica Europske unije s ostatkom svijeta.

- Konkurentnost i inovacije:
 - Privatna ulaganja, radna mjesta i bruto dodana vrijednost;
 - Patenti koji se odnose na recikliranje i sekundarne sirovine.

Indikatori su veoma važni za evaluaciju, praćenje (nadzor) i poboljšanje raznih politika i programa koji imaju za cilj uvođenje/poboljšanje koncepta kružnoga gospodarstva (Geng, Fu, Sarkis, i Xue, 2012).

U sljedećoj tablici se osim indikatora koji govore o primjeni kružnoga gospodarstva analizira i glavni makroekonomski indikator, bruto domaći proizvod (BDP), koji objašnjava ekonomski učinak gospodarstva neke zemlje. Glavni ekonomski ciljevi svake države su visoki i brzi rast proizvodnje, niska nezaposlenost i stabilne cijene, što nužno ne treba biti u koliziji sa zaštitom okoliša. Upravo implementacijom koncepta kružnoga gospodarstva može se ostvariti gospodarski razvoj, a time i rast BDP-a uz očuvanje okoliša i smanjenje korištenja prirodnih resursa. Neki od važnijih indikatora primjene kružnoga gospodarstva i ekonomskog razvoja u Europskoj uniji prikazani su u tablici 3.

Tablica 3. Važniji indikatori primjene kružnoga gospodarstva i ekonomskog razvoja u Europske unije (prosjek 2000. – 2019.)

Zemlja	BDP po stanovniku u EUR	Broj patenata povezanih s recikliranjem i sekundarnim sirovinama	Proizvodnja komunalnog otpada po stanovniku / godina	komunalnog otpada u (%)	Stopa recikliranja biootpada u kg/stanovniku	e otpada u (%)
Austrija	36.935	10,4	581	60	199	41
Belgija	34.730	8,4	453	54	97	33
Bugarska	5.281	0,6	493	23	9	69
Cipar	23.612	0,3	662	9	5	20
Češka	15.689	11,7	332	16	13	36
Danska	47.303	4,4	769	44	127	45
Estonija	12.552	0,4	376	20	14	39
Finska	36.441	10,7	496	36	54	38
Francuska	32.461	39	528	35	84	28
Grčka	19.714	0,2	554	15	11	27
Hrvatska	11.012	0,3	384	14	7	70
Irska	44.871	2,6	563	31	23	42
Italija	28.436	18,4	520	31	62	29
Litva	9.777	1,2	353	13	10	27
Latvija	10.261	0,9	418	18	31	34
Luksemburg	82.751	2,2	689	45	127	37
Njemačka	33.871	103	609	62	102	37
Nizozemska	40.230	14,2	564	49	144	34
Mađarska	10.949	2,7	420	19	15	39
Malta	17.961	0,2	614	8	17	13
Poljska	9.883	22,2	304	16	11	29
Portugal	17.698	1,8	473	20	49	33
Rumunjska	7.003	2,5	320	7	10	16
Slovačka	12.782	1,3	311	13	16	41
Slovenija	18.420	0,7	469	30	26	29
Španjolska	24.326	19,9	537	31	81	27
Švedska	41.739	4,1	457	46	58	56
Velika Britanija	32.012	21,2	531	33	60	36

Izvor: ec.europa.eu/eurostat/web/circular-economy/indicators/monitoring-framework

Zemlje s najvećim količinama proizvedenog komunalnog otpada po stanovniku su: Danska (769 kg), Luksemburg (689 kg) i Cipar (662 kg). Pozitivan primjer zemalja koje stvaraju manju količinu otpada su: Poljska (304 kg), Slovačka (311 kg), Rumunjska (320 kg) i Češka (332 kg). Ako se ovi podatci promatraju u kontekstu ekonomskog razvoja, može se vidjeti da su Danska i Luksemburg zemlje s izuzetno visokim BDP-om. S druge strane, Cipar je zemlja u kojoj je turizam jako razvijen pa je i to jedan od faktora ovako visoke količine proizvedenog otpada. No osim što se otpad proizvodi, važno je i koliko se on reciklira. Stopa recikliranja pokazuje da iako pojedine zemlje stvaraju veliku količinu otpada imaju dobre pokazatelje u sektoru recikliranja. Tako najveću stopu recikliranja komunalnog otpada ima Njemačka (62%), Austrija (60%) Belgija (54%) te Nizozemska (49%). Kada se promatra recikliranje biootpada, najbolje rezultate ostvaruje Austrija sa 199 kg/po stanovniku, Nizozemska sa 144 kg/po stanovniku, Danska i Luksemburg sa 127 kg/po stanovniku. Kada se analizira recikliranje e-otpada, može se vidjeti da Hrvatska ima najveću stopu recikliranja od 70%, a nakon nje slijede Bugarska sa 69%, Švedska sa 56% i Danska sa 45%. Zemlja s daleko najvećim brojem godišnjih патената povezanih s recikliranjem i sekundarnim sirovinama je Njemačka (103).

4. MOGUĆNOSTI FINANCIRANJA KRUŽNOGA GOSPODARSTVA

Financiranje tranzicije nije jednostavan i jeftin proces. Iako se prednosti kružnoga gospodarstva sve više prepoznaju, još uvijek postoje mnoge prepreke koje ometaju prijelaz na kružni model u poduzećima. Neki autori ukazuju da je problem u neadekvatnim financijskim programima, nedostatku financijskih sredstava (Aranda-Uson, Portillo-Tarragona, Marin-Vinuesa i Scarpellini, 2019; Ormazabal, Sandoval-Prieto, Leal-Puga i Jaca, 2018), ali i nedostatku potpore javnih institucija (Ormazabal, Prieto-Sandoval, Jaca i Santos, 2016). Stoga je dostupnost izvora financiranja inovacija jedan od najvažnijih elemenata tranzicije putem kojih se implementira kružno gospodarstvo i novi model poslovanja (European Commission [EC], 2019; Ghisetti i Monteresor, 2020). Početna ulaganja potrebna za izgradnju infrastrukture kružnoga gospodarstva, kao što su razvoj eko-industrije, sustavi prikupljanja i recikliranja otpada ili rješenja za čistu vodu i kanalizaciju temeljena na kružnim tehnologijama, mogu predstavljati značajan izazov za zemlje u razvoju i nerazvijene zemlje.

Financijska sredstva su potrebna u cilju osiguranja strukturnih promjena u proizvodnji i potrošnji uz tehnološke modifikacije radi poboljšanja gospodarske učinkovitosti i optimiziranje korištenja financijskog kapitala (United Nations Environment Programme [UNEP], 2020).

U ožujku 2020. godine Grupa stručnjaka za financiranje prijelaza na kružno gospodarstvo objavila je "opći, sektorsko-agnostički sustav kategorizacije kružnoga gospodarstva kojim se (UNEP, 2020)":

- definiraju razne aktivnosti koje značajno doprinose kružnom gospodarstvu;
- utvrđuje set minimalnih kriterija koje moraju ispunjavati aktivnosti u okviru svake definirane kategorije, a u cilju intenziviranja prijelaza na kružno gospodarstvo;
- metodološke smjernice koje uključuju indikativni popis ulaganja i projekata za svaku kategoriju kružnoga gospodarstva.

Postoje četiri modela putem kojih se može financirati prijelaz s linearne ekonomije na kružno gospodarstvo, i to (UNEP, 2020):

1. Model povrata vrijednosti resursa

Ovaj model obuhvaća: odvojeno prikupljanje i gospodarenje otpadom, kao i suvišnim proizvodima, dijelovima i materijalima koji omogućuju kružno zadržavanje vrijednosti. Otpad i ostatci biomase pretvaraju se u: hranu za ljude, hranu za životinje, hranjive tvari, gnojiva, materijale na bio osnovi ili kemijske sirovine ili se ponovno upotrebljavaju/recikliraju.

2. Modeli kružnoga dizajna i proizvodnje

Dizajn i proizvodnja usmjereni su na: povećanje učinkovitosti materijala/resursa, veću trajnost, funkcionalnost, modularnost, nadogradnju, jednostavno rastavljanje i popravke; materijale koji se mogu reciklirati ili kompostirati i obraditi. Tehnološki proces podržava kružne prednosti. Tako je eko-dizajn pristup kojim se razmatra utjecaj proizvoda na okoliš tijekom njegova cijelog životnog ciklusa. Eko-dizajn također može olakšati popravke i optimizirati procese ponovne proizvodnje, dodatno štedeći resurse. Politike eko-dizajna uglavnom su se usredotočile na energetska učinkovitost.

3. Model za optimalnu uporabu

Implementacija ovog modela znači ponovnu uporabu, popravak, obnovu, prenamjenu i preradu istrošenog proizvoda, proizvoda kojemu je istekao rok trajanja ili suvišnog proizvoda, ali i bilo koje vrste imovine. Isto tako ovaj model obuhvaća sanaciju degradiranog zemljišta radi povratka u korisno stanje. Međunarodna komisija za resurse procjenjuje da se, zahvaljujući učinkovitosti materijalnih resursa, mogu postići značajna smanjenja emisija u korištenju materijala u sektoru građevinarstva i transporta: ona se kreću između 60 i 80 posto diljem G7, Indije i Kine.

4. Kružna podrška, pokretači, tržišta

Ovaj model u sebi obuhvaća postojanje i dijeljenje stručnog znanja, savjeta i alata, softverskih aplikacija i tržišta. Isto tako potrebno je omogućavati usluge za sve ostale poslovne modele kružnoga gospodarstva.

Rast i implementacija ovih kružnih modela zahtijevat će strukturnu promjenu u sustavu proizvodnje i potrošnje te odgovarajuće tehnološke promjene i inovacije. Inovacije su ključni element strukturnih i tehnoloških promjena koje se očekuju u budućnosti. One se mogu javiti u obliku inovacija u globalnim opskrbnim lancima putem kojih će se optimizirati taj proces. Promjenom shvaćanja mijenja se ravnoteža između prodaje proizvoda i usluga pri čemu usluge postaju pokretač transakcija. Osim inovacija važno je osigurati poboljšanje pristupa raznim materijalima uz pomoć ponovnog korištenja otpada kao resursa. Dakle, ono što se prije smatralo otpadom sada se smatra resursom. Jedan od važnijih elemenata implementacije kružnoga gospodarstva je i suradnja dionika tijekom cijelog lanca opskrbe gdje se poduzimaju zajednički koraci u cilju koordiniranja procesa sastavljanja i rastavljanja proizvoda i usluga radi povećanja njihove vrijednosti.

Cjelokupan proces transformacije s linearnog na kružno gospodarstvo zahtijeva određena financijska sredstva, što čini put prelaska kompliciranijim. Glavni element financiranja svih projekata koji se događaju na razini Europske unije definira kohezijska politika. Kohezijska politika strategija je Europske unije za promicanje i podupiranje "ukupnog skladnog razvoja" njezinih država članica i regija. Ima za cilj učvrstiti gospodarsku i socijalnu koheziju smanjenjem nejednakosti u razini razvoja između regija i država, a podržava otvaranje novih radnih mjesta, konkurentnost poslovanja, gospodarski rast, održivi razvoj i poboljšanje

kvalitete života građana (https://ec.europa.eu/regional_policy/en/policy/what/investment-policy/). Kohezijska politika ostvaruje se kroz sljedeće fondove:

- Europski fond za regionalni razvoj (ERDF) – ima cilj ojačati gospodarsku, društvenu i teritorijalnu koheziju u Europskoj uniji ispravljanjem neravnoteža među njezinim regijama. U razdoblju 2021. – 2027. omogućit će ulaganja u pametniju, zeleniju, povezaniju i društveniju Europu koja je bliža njezinim građanima.
- Kohezijski fond (CF) za ulaganje u okoliš i promet u manje prosperitetnim zemljama EU – podržava ulaganja u područje okoliša i transeuropske mreže u području prometne infrastrukture.
- Europski socijalni fond plus (ESF+) za potporu zapošljavanju i stvaranje poštenog i socijalno uključivog društva u zemljama Europske unije – sredstva fonda ulažu se u ljude, s naglaskom na poboljšanje mogućnosti zapošljavanja i obrazovanja diljem Europske unije.
- Fond za pravednu tranziciju (JTF) za podršku regijama koje su najviše pogođene prijelazom na klimatsku neutralnost. Ovaj fond je novi instrument Kohezijske politike 2021. – 2027. i ima za cilj postizanje klimatske neutralnosti EU do 2050. godine. Aktivnosti koje podržava JTF uključuju: ulaganja u tvrtke, istraživanje i inovacije, tehnologije čiste energije, smanjenje emisija stakleničkih plinova, digitalizaciju, regeneraciju web stranica, kružno gospodarstvo, usavršavanje i prekvalifikaciju radnika, pomoć tražiteljima posla.

U razdoblju od 2021. do 2027. godine sredstva EU dodijeljena Kohezijskoj politici iznose 392 milijarde EUR. Uz nacionalno sufinanciranje, oko pola bilijuna eura bit će na raspolaganju za financiranje programa u regijama i zemljama EU. Kroz sve ove programe mogu se financirati projekti koji se odnose na kružno gospodarstvo.

Isto tako Europska investicijska banka osigurava kredite, ali i savjete za kružne projekte kroz Europske fondove. Europska investicijska banka u cilju podupiranja projekata kružnoga gospodarstva namjerava u idućih 5 godina alocirati 10 milijardi EUR u obliku zajmova, investicija, jamstava i usluga savjetovanja (Dewick, Bengtsson, Cohen, Sarkis i Schorder, 2020). Mnoge vlade diljem svijeta uključile su elemente kružnoga gospodarstva u svoje nacionalne razvojne planove. Strategije uključuju ciljeve za recikliranje i ponovnu uporabu otpadnih materijala, kao i planove za

povezivanje kružnoga gospodarstva i klimatskih akcija, te planove za poticanje inovacija i otvaranje novih radnih mjesta prelaskom na kružno gospodarstvo. Tako je finska vlada stvorila nove financijske instrumente i aranžmane za subvencioniranje ulaganja kao dio provedbe nacionalnog puta na kružno gospodarstvo. Osim toga za financiranje tranzicije koriste se razna ulaganja nacionalnih banaka i institucionalnih ulagača, poput mirovinskih fondova.

Poticanje ulaganja u kružno gospodarstvo može se postići i primjenom raznih fiskalnih politika i poreznih sustava. Transformacija poreznih sustava na međunarodnoj i nacionalnoj razini ključna je za prelazak na inkluzivno kružno gospodarstvo. Porezni sustavi, u nekim slučajevima, nedostatak poreza, način su da nacionalne vlade privuku tvrtke da se transformiraju na kružni model privređivanja. U smislu kružnoga gospodarstva, zemlje mogu ostvariti ekonomsku prednost strukturirajući svoje porezne poticaje prema svojim prioritetima. Usklađivanje poreznih poticaja ima smisla za zemlje koje na svom području nemaju određene kritične resurse ključne za njihov gospodarski razvoj ili za rješavanje neugodnih ekoloških pitanja povezanih s tokovima otpada. Porezne mjere mogu se javiti u sljedećim oblicima (UNEP, 2020):

- Porezi na plastiku – kako bi se smanjila količina plastičnog otpada i promicao prijelaz na kružnu ekonomiju, prijedlozi politika uključivali su različite oblike oporezivanja plastike za jednokratnu upotrebu. Do sada su se u većini zemalja te reforme koncentrirale na primjenu poreza na razini potrošača (npr. oporezivanje i naplaćivanje plastičnih vrećica u supermarketima), a od 2021. godine na razini Europske unije donesen je zakon o zabrani korištenja jednokratne plastike. Porezi na plastiku mogu se odnositi i na sirovine koje se u procesu proizvodnje koriste (npr. neobrađena plastika i reciklirani materijali). Iako nacionalne vlade općenito ne izdvajaju porezne prihode za posebne svrhe, prihodi od poreza na plastiku mogli bi se dodijeliti za poboljšanje infrastrukture za prikupljanje i recikliranje plastike.
- Porezi na ekstrakciju sirovina – porezi na iscrpljivanje pijeska i šljunka koji se koriste u građevinarstvu uvele su različite zemlje članice Europske unije, stvarajući poticaje za recikliranje građevinskog otpada. Zemlje u razvoju obično nude manja porezna opterećenja, a svaki pokušaj povećanja ovih poreza može dovesti do bijega kapitala.

- Smanjenje poreza na dodanu vrijednost (PDV) za ponovnu uporabu i popravak – okvir oporezivanja kružnoga gospodarstva koji se može primijeniti tijekom životnog ciklusa proizvoda trebao bi uključivati porezne olakšice na aktivnostima ponovne uporabe i popravka, upotrebu recikliranih proizvoda te za preprodaju proizvoda.
- Prebacivanje poreznog opterećenja s rada ili obrazovanja na materijalne inpute – procesi prikupljanja, uporabe i prerade sekundarnih materijala nisu jednostavni postupci i za njih je potrebna velika količina rada. Smanjivanjem oporezivanja rada smanjili bi se troškovi prikupljanja i razvrstavanja otpada, čime bi sekundarni materijali postali konkurentniji primarnim materijalima. Slično, ponovna proizvodnja i obnova proizvoda relativno su radno intenzivni u usporedbi s proizvodnjom novih proizvoda, posebno s obzirom na sve veću upotrebu automatizacije u proizvodnim aktivnostima. Ovi procesi zahtijevaju određeni skup vještina pa mogući nedostatak kvalificirane stručne radne snage također može biti problem. Kreatori politike mogli bi razmotriti fiskalne poticaje koji podržavaju osposobljavanje i zapošljavanje u tvrtkama s kružnim gospodarstvom.
- Politike za privlačenje izravnih stranih ulaganja bit će važne za nerazvijene zemlje i zemlje u razvoju. Smanjeni tijekovi izravnih stranih ulaganja u zemlje u razvoju zbog pandemije utjecali su na izvozno orijentirane zemlje. Međutim, mnoge politike prije pandemije koje su promicale i upravljale izravnim stranim ulaganjima bile su uglavnom neodgovarajuće za sprječavanje štete po okoliš i napredak u zaštiti okoliša. Politike ulaganja obično uključuju smanjenje fiskalnog i regulatornog opterećenja izravnih stranih ulaganja, što je upravo suprotno od onoga što je potrebno za unapređenje kružnih poslovnih modela. Iako ih je teško definirati, nekoliko koncepata, poput niskouglićnih izravnih stranih ulaganja ili zelenih izravnih stranih ulaganja, mogu donijeti koristi. Sporazumi o zelenim izravnim stranim ulaganjima mogu se proširiti uključivanjem odredbi za ulaganja u kružno gospodarstvo.

Privatni sektor nužno treba kapital putem kojeg će se financirati razvoj kružnoga gospodarstva. Postoje četiri glavna instrumenta koji se javljaju kao potencijalni izvori za ulaganje u kružna rješenja, što se prikazuje u tablici 4.

Tablica 4. Instrumenti za smanjenje rizika financiranja modela kružnoga gospodarstva

Instrument	Opis	Upotreba za financiranje kružne ekonomije
Jamstvo za kredite	Jamstvo za kredite koje daje vlada može olakšati i potaknuti poslovne banke da financiraju zajmove malim tvrtkama koje zbog visokog rizika ili nedostatka kolaterala ne mogu dobiti konvencionalne kredite.	Ovaj se instrument može koristiti za mala i srednja poduzeća u nerazvijenim i zemljama u razvoju za ulaganje u kružna rješenja.
Osiguranje rizika	Osiguranje rizika se koristi kao alat za tvrtke u cilju umanjenja rizika koji proizlaze iz nepovoljnog okruženja. Osiguranje rizika pomaže tvrtkama u stvaranju stabilnijeg okruženja za ulaganja i kreiranju boljeg pristupa financiranju.	Instrument osiguranja rizika koristio se za olakšavanje financiranja infrastrukturnih projekata i ulaganja. Ovaj instrument bi se mogao koristiti za financiranje infrastrukture potrebne za kružno gospodarstvo, poput fiksne širokopojasne veze, infrastrukture za gospodarenje otpadom i recikliranje.
Javna ulaganja	Ovaj je instrument predstavlja ulaganje u kojem su partneri investicijskih fondova uložili izravno u operativno društvo. Javna ulaganja omogućuju veća ulaganja, a izbjegavaju se problemi s izloženošću riziku.	Ovaj instrument bi se mogao koristiti za financiranje projekata regenerativnog šumarstva.
Mješovito financiranje (Javno-privatno partnerstvo)	Mješovito javno-privatno financiranje ima za cilj iskoristiti ulaganja iz javnog sektora za poticanje komercijalnih financija za javno dobro. Mješovito financiranje pomaže u prevladavanju velikih prepreka privlačenjem prijeko potrebnog privatnog kapitala.	Mješovito financiranje primijenjeno je za stvaranje mogućnosti ulaganja u zemljama u razvoju kako bi se pomoglo u postizanju ciljeva održivog razvoja, skupljajući dodatna sredstva privatnog sektora u većim količinama. Primjeri uključuju financiranje vode i kanalizacije te projekte koji rezultiraju čistom energijom.

Izvor: Schroder i Raes (2021). Financing an inclusive circular economy; De-risking investments for circular business models and the SDGs, dostupno online: <https://www.chathamhouse.org/2021/07/financing-inclusive-circular-economy/03-de-risking-financing-circular-economy-0>

Financiranje kružnoga gospodarstva razvijalo se tijekom vremena i doživjelo pomak u financijskom sektoru prema održivim kreditima i održivim ulaganjima. No još uvijek financiranje kružne ekonomije ima manje razmjere nego financiranje ostalih oblika zelenih projekata. U financijskom razdoblju Europske unije (2021. – 2027.) ulagat će se u one

projekte koji će osiguravati primjenu kružnoga gospodarstva, zelene ekonomije i digitalizacije te je tu činjenicu u cilju osiguranja održivog razvoja i očuvanja okoliša potrebno iskoristiti.

5. ZAKLJUČAK

Predmet istraživanja ovog rada je kružno gospodarstvo koje teži razvoju novih tehnologija, inovacija, dizajna te novom organizacijskom ustroju. Linearni model gospodarenja koji se trenutno u najvećoj mjeri upotrebljava temelji se na uvjerenju da su resursi neiscrpni i da postoji neograničen prostor za odlaganje otpada. Iz ovoga se može vidjeti da je takav model neodrživ i da je potrebno učiniti određene promjene. Tranzicija na kružno gospodarstvo zahtijeva promjene ne samo jedne aktivnosti već čitavog sustava poput industrije, društveno socijalne komponente, energetike, prijevoza, poljoprivrede itd. Svaki sektor gospodarstva ima svoje zakonitosti i ograničenja, kao što i svaka zemlja Europske unije ima svoje specifičnosti, što rezultira različitim pristupom i tempom tranzicije na kružno gospodarstvo. No ovaj način privređivanja može donijeti i neke koristi poput godišnje uštede troškova u iznosu od 620 milijuna EUR u Europi i uštedu sirovina u iznosu od 17 do 24%. Procjenjuje se da bi primjena koncepta kružnoga gospodarstva mogla povećati bruto domaći proizvod (BDP) Europske unije za dodatnih 0,5% i kreirati oko 700.000 novih radnih mjesta do 2030. godine.

Za tranziciju na kružno gospodarstvo potrebna su značajna financijska sredstva jer je potrebno mijenjati mnoštvo ustaljenih načina razmišljanja, proizvodnje, manipulacije otpadom i slično. Na razini Europske unije, u posljednje vrijeme, na raspolaganju su značajna sredstva koja zemlje članice mogu iskoristiti za tranziciju. Dostupnost sredstava, ali i informiranost zainteresiranih dionika važan je element u prihvatanju i implementaciji koncepta kružnoga gospodarstva. Ovaj koncept može pomoći dionicima da preduhitre ograničenja koja mogu biti u obliku nedostatka resursa, eksternalija, poreznih opterećenja i slično. Primjenom koncepta kružnoga gospodarstva može se otvoriti značajan broj novih radnih mjesta, ali i uštedjeti na sirovinama.

LITERATURA

Andabaka, A. (2018). Potencijali i ograničenja primjene kružne ekonomije u kontekstu održivoga razvoja Hrvatske, U Družić, G., Družić, I. (ur.). Zbornik radova znanstvenog skupa: Modeli razvoja hrvatskog gospodarstva, Ekonomski fakultet Zagreb, Zagreb, 427–458.

Andabaka, A., Beg, M. i Gelo, T. (2018). Challenges of Circular Economy in Croatia. *International Journal of Multidisciplinary Business Science*, 4, 115–126.

Aranda-Uson A., Portillo-Tarragona, P., Marin-Vinuesa, L. M. i Scarpellini, S. (2019). Financial Resources for the Circular Economy: A Perspective from Business. *Sustainability*, 11/3, 888, doi: <https://doi.org/10.3390/su11030888>

BIO by Deloitte (2015). Study on Data for a Raw Material System Analysis: Roadmap and Test of the Fully Operational MSA for Raw Materials. Prepared for the European Commission, DG GROW, dostupno na: https://ec.europa.eu/assets/jrc/msa/images/msa_final_report.pdf

Bocken, N. M. P., Olivetti, E. A., Cullen, J. M., Potting, J. i Lifset, R. (2017). Taking the Circularity to the Next Level: A Special Issue on the Circular Economy. *Journal of Industrial Ecology*, 21, 476–482, doi:10.1111/jiec.12606.

Car, S. i Jelavić, V. (2016). Nove mogućnosti tehnološkog razvoja u okrilju nisko ugljične strategije EU. *Polytechnic and Design*, 4, 266–276, doi:10.19279/TVZ.PD.2016-4-3-05.

Cullen, J. M. i Allwood, J. M. (2013). Mapping the Global Flow of Aluminium: From Liquid Aluminium to End-Use Goods. *Environmental Science and Technology*, 47, 3057–3064, doi:10.1021/es304256s.

Dewick, P., Bengtsson, M., Cohen, M. J., Sarkis, J. i Schorder, P. (2020). Circular Economy Finance, Clear Winner of Risky Proposition, *Journal of Industrial Ecology*, 24(6), 1192-1200, doi: <https://doi.org/10.1111/jiec.13025>

Domenech, T. i Bahn-Walkowiak, B. (2019). Transition Towards a Resource Efficient Circular Economy in Europe: Policy Lessons From the EU and the Member States. *Ecological Economy*, 155, 7–19, doi:10.1016/j.ecolecon.2017.11.001.

Drljača, M. (2015). Koncept kružne ekonomije. Kvaliteta i izvornost IV, 18–22.

EASAC. (2016). Indicators for a Circular Economy. EASAC, ed.; EASAC Policy Report 30; Deutsche Akademie der Naturforscher Leopoldina: Halle (Saale), Germany, 25-57.

Ellen MacArthur Foundation. (2013). Towards the Circular Economy: Economic and Business Rationale from an Accelerated Transition, dostupno na:

<https://www.ellenmacarthurfoundation.org/assets/downloads/publications/Ellen-MacArthur-Foundation-Towards-the-Circular-Economy-vol.1.pdf>

European Commission. (2019). Accelerating the Transition to the Circular Economy: Improving Access to Finance for Circular Economy Projects

European Union. (2020). Circular Economy Action Plan: For a Cleaner and More Competitive Europe, dostupno na: https://ec.europa.eu/environment/pdf/circular-economy/new_circular_economy_action_plan.pdf

Fischer, A. i Pascucci, S. (2017). Institutional Incentives in Circular Economy Transition: The Case of Material Use in the Dutch Textile Industry. *Journal of Cleaner Production*, 155, 17–32, doi:10.1016/j.jclepro.2016.12.038.

Franklin-Johnson, E. L., Figge, F. i Canning, L. (2016). Resource Duration as a Managerial Indicator for Circular Economy Performance. *Journal of Cleaner Production*, 133, 589–598, doi:10.1016/j.jclepro.2016.05.023.

Geisendorf, S. i Pietrulla, F. (2018). The Circular Economy and Circular Economic Concepts: A Literature Analysis and Redefinition. *Thunderbird International Business Review*, 60, 771–782, doi:10.1002/tie.21924.

Geissdoerfer, M., Savaget, P., Bocken, N. M. P. i Hultink, E. J. (2017). The Circular Economy – A New Sustainability Paradigm. *Journal of Cleaner Production*, 143, 757–768, doi:10.1016/j.jclepro.2016.12.048.

Geng, Y., Fu, J., Sarkis, J. i Xue, B. (2012). Towards a National Circular Economy Indicator System in China: An Evaluation and Critical Analysis. *Journal of Cleaner Production*, 23, 216–224, doi:10.1016/j.jclepro.2011.07.005.

Geng, Y., Zhu, Q., Doberstein, B. i Fujita, T. (2009). Implementing China's Circular Economy Concept at the Regional Level: A Review of Progress in

Dalian, China. *Waste Management*, 29, 996–1002, doi:10.1016/j.wasman.2008.06.036.

Ghisellini, P., Cialani, C. i Ulgiati, S. (2016). A Review of Circular Economy: The Expected Transition to a Balanced Interplay of Environmental and Economic Systems. *Journal of Cleaner Production*. 114, 11–32, doi:10.1016/j.jclepro.2015.09.007.

Ghissetti, C. i Montresor, S. (2020). On the Adoption of Circular Economy Practices by Small and Medium-Size Enterprises (SMEs): Does "Financing –as –Usual" Still Matter?, *Journal of Evolutionary Economies*, 30, 559–586, doi:10.1007/s00191-019-00651-w

Graedel, T. E., Harper, E. M., Nassar, N. T. i Reck, B. K. (2015). On the Materials Basis of Modern Society. *Proceedings of the National Academy of Science of the USA*, 112, 6295–6300, doi:10.1073/pnas.1312752110.

Hashimoto, S., Moriguchi, Y., Saito, A. i Ono, T. (2004). Six Indicators of Material Cycles for Describing Society's Metabolism: Application to Wood Resources in Japan. *Resources Conservation and Recycling*, 40, 201–223, doi:10.1016/S0921-3449(03)00101-0.

Hashimoto, S., Tanikawa, H. i Moriguchi, Y. (2009). Framework for Estimating Potential Wastes and Secondary Resources Accumulated Within an Economy – A Case Study of Construction Minerals in Japan. *Waste Management*, 29, 2859–2866, doi:10.1016/j.wasman.2009.06.011.

Hass, W., Krausmann, F., Wiedenhofer, D. i Heinz, M. (2015). How Circular Is the Global Economy? An Assessment of Material Flows, Waste Production, and Recycling in the European Union and the World in 2005. *Journal of Industrial Ecology*, 19, 765–777, doi:10.1111/jiec.12244.

Haupt, M., Vadenbo, C. i Hellweg, S. (2016). Do We Have the Right Performance Indicators for the Circular Economy? Insight into the Swiss Waste Management System. *Journal of Industrial Ecology*, 21, 615–627, doi:10.1111/jiec.12506.

Jawahir, I. S. i Bradley, R. (2016). Technological Elements of Circular Economy and the Principles of 6R-Based Closed-Loop Material Flow in Sustainable Manufacturing. *Procedia CIRP*, 40, 103–108, doi:10.1016/j.procir.2016.01.067.

Korhonen, J., Honkasalo, A. i Seppala, J. (2018). Circular Economy: The Concept and Its Limitations. *Ecological Economy*, 143, 37–46, doi:10.1016/j.ecolecon.2017.06.041.

Kovanda, J. (2014). Incorporation of Recycling Flows into Economy-Wide Material Flow Accounting and Analysis: A Case Study for the Czech Republic. *Resources Conservatory and Recycling*, 92, 78–84, doi:10.1016/j.resconrec.2014.08.006.

Lieder, M. i Rashid, A. (2016). Towards Circular Economy Implementation: A Comprehensive Review in Context of Manufacturing Industry. *Journal of Cleaner Production*, 115, 36–51, doi:10.1016/j.jclepro.2015.12.042.

Mayer, A., Haas, W., Wiedenhofer, D., Krausmann, F., Nuss, P. i Blengini G. A. (2019). Measuring Progress Towards a Circular Economy, A Monitoring Framework for Economy-Wide Material Loop Closing in the EU 28., *Journal of Industrial Ecology*, 23, 62–76, doi:10.1111/jiec.12809.

McDowall, W., Geng, Y.J., Huang, B., Baretekova, E., Lbeischwitz, R., Turkeli, S., Kemp, R. i Domenech T. (2017). Circular Economy Policies in China and Europe, *Journal of Industrial Ecology*, 21(3), 651–661, doi.org/10.1111/jiec.12597

Nuss, P., Blengini. G. A., Hass, W., Mayer, A., Nita, V. i Pennington, D. (2017). Development of a Sankey Diagram of Material Flows in the EU Economy Based on Eurostat Dana. EUR 28811 EN, JRC technical reports; Publications Office of the European Union: Luxembourg, dostupno na: <https://ec.europa.eu/jrc/en/publication/development-sankey-diagram-material-flows-eu-economy-based-eurostat-data>

Ormazabal, M., Prieto-Sandoal, V., Jaca, C. i Santos, J. (2016). An Overview of the Circular Economy among SMEs in the Basque Country: A Multiple Case Study. *Journal of Industrial Engineering Management*, 9, 1047–1058.

Ormazabal, M., Prieto-Sandoval, V., Puga-Leal, R. i Jaca, C. (2018). Circular Economy in Spanish SMEs: Challenges and Opportunities. *Journal of Cleaner Production*, 185, 157–197.

Ozili, P. K. (2021). Circular Economy, Banks, and Other Financial Institutions: What's in It for Them?. *Circular Economy and Sustainability*, <https://doi.org/10.1007/s43615-021-00043-y>

Pauliuk, S., Wang, T. i Muller, D. B. (2012). Moving Toward the Circular Economy: The Role of Stocks in the Chinese Steel Cycle. *Environmental Science and Technology*, 46, 148–154, doi:10.1021/es201904c.

Reck, B. K. i Graedel, T. E. (2012). Challenges in Metal Recycling, *Science*, 337, 690–695, doi:10.1126/science.1217501.

Ribić, B., Voća, N. i Ilakovac, B. (2017). Concept of Sustainable Waste Management in the City of Zagreb, Towards the Implementation of Circular Economy Approach. *Journal of Air Waste Management Association*, 67, 241–259, doi:10.1080/10962247.2016.1229700.

Rudan, E., Krstinić Nižić, M. i Šverko Grdić, Z. (2021). Effect of Circular Economy on the Sustainability of Cultural Tourism (Croatia). *Ekonomia i Srodowisko*, 1(76), 120-138.

Runko Luttemberger, L., Vujević, D., Šijeg, M. i Gudelj, I. (2015). Postizanje resursne učinkovitosti objedinjavanjem sektora energetike, vode i otpada. *Inženjerstvo okoliša*, 2, 23–28.

Schroder, P. i Raes, J. (2021). Financing an Inclusive Circular Economy; De-risking Investments for Circular Business Models and the SDGs, dostupno na: <https://www.chathamhouse.org/2021/07/financing-inclusive-circular-economy/03-de-risking-financing-circular-economy-0>

Stankevičiene, J., Nikanorova, M. i Cera G., (2020). Analysis of Green Economy Dimension in the Context of Circular Economy: The Case of Baltic Sea Region. *Economics*, XXIII, doi: 10.15240/tul/001/2020-1-001

Tišma, S., Boromisa, A. M., Funduk, M. i Čermak, H. (2017). Okolišne politike i razvojne teme. *Alineja*, Zagreb, Hrvatska

Tukker, A. (2015). Product services for a resource – Efficient and Circular Economy – A Review. *Journal of Cleaner Production*, 97, 76-91, doi:10.1016/j.jclepro.2013.11.049.

United Nations Environment Programme (UNEP) (2020). *Financing Circularity: Demystifying Finance for Circular Economies*.

Van Weelden, E., Mugge, R. i Bakker, C. (2016). Paving the Way Towards Circular Consumption: Exploring Consumer Acceptance of Refurbished Mobile Phones in the Dutch Market. *Journal of Cleaner Production*, 113, 743–754, doi:10.1016/j.jclepro.2015.11.065.

Wang, T., Muller, D. B. i Graedel, T. E. (2007). Forging the Anthropogenic Iron Cycle. *Environmental Science Technology*, 41, 5120–5129, doi:10.1021/es062761t.

Webster, K. (2017). *The Circular Economy: A Wealth of Flows*,. 2nd ed.; Ellen MacArthur Foundation Publishing

Yuan, Z., Bi, J. i Moriguchi, Y. (2006). The Circular Economy, A New Development Strategy in China. *Journal of Industrial Ecology*, 10, 4–8.

ec.europa.eu/eurostat/web/circular-economy/indicators/monitoring-framework, Monitoring Framework (pristupljeno: 10. srpnja 2021.)

www.davor-skrlec.eu, Škrlec, D. Rok za prelazak Hrvatske na kružno gospodarstvo (pristupljeno: 15. srpnja 2021.)

https://ec.europa.eu/environment/topics/waste-and-recycling/waste-framework-directive_en, Waste Framework Directive (pristupljeno: 7. listopada 2021.)

https://ec.europa.eu/regional_policy/en/policy/what/investment-policy/, The EU's Main Investment Policy (pristupljeno: 7. listopada 2021.)

FINANCING THE CIRCULAR ECONOMY TRANSITION

Abstract

Due to the existing unsustainable linear mode of production, there is a need to introduce a circular economy model that enables economic growth and prosperity while being consistent with environmental protection and sustainable development. The economic disruption caused by the pandemic in 2020 has intensified deliberations on a more urgent transition to the concept of sustainable consumption and production, which is closely linked to the concept of circular economy. For the transition, among other important elements, it is necessary to provide financial resources that will enable a faster and easier transition to the new way of doing business. At the same time, securing sufficient financial resources is crucial for the introduction of circular economy, and the success of its implementation also depends on their quantity.

The aim of this paper is to emphasize the importance of implementing the concept of circular economy in the economy and providing sufficient financial resources to ensure the transformation. To this end, the paper analyzes the possibilities of financing the transition through existing funds and other sources of money that can successfully and fully implement the concept of circular economy at the level of the European Union and consequently the Republic of Croatia. The scientific contribution of the paper is reflected in the presented theoretical concept in relation to the concept of circular economy, in the presentation of the progress in the implementation of circular economy in the EU economies and in the presentation of financing options through which the transition could be accelerated. The results show that the transition to a circular economy will require significant financial resources. Significant funds have recently become available at the EU level for Member States to use for the transition. The paper opens the opportunity to further explore this issue in terms of the use of finance and the process of successfully implementing this method of production in the economy.

Keywords: circular economy, financing, sustainability, economic development.

JEL klasifikacija: J20, J22, J23
Pregledni rad

ANALIZA MEĐUODNOSA PONUDE I POTRAŽNJE NA TRŽIŠTU RADA U REPUBLICI HRVATSKOJ¹

Tomislav Globan*

SAŽETAK

Cilj ovog rada je kvantificirati međudnos ponude i potražnje na hrvatskom tržištu rada te unaprijediti postojeću prezentaciju aktualnih trendova na tržištu rada kroz nove, vizualno atraktivne, dinamičke i interaktivne grafičke prikaze i indikatore. U radu se iznose dva prijedloga takvih unaprjeđenja: i) Dinamička vizualizacija stanja na tržištu rada kroz vrijeme i kroz različite poslovne cikluse; ii) Izrada novog indikatora – Semafora tenzije tržišta rada – koji predstavlja procjenu ponude i potražnje za radom u Republici Hrvatskoj te dinamički prikaz njihove usklađenosti kroz vrijeme. S metodološkog aspekta, u prvom se koraku podaci desezoniraju metodom Census X12 kako bi se iz podataka isključio utjecaj sezonskih kretanja na tržištu rada koja su u Hrvatskoj izrazito prisutna. Potom se podaci ekonometrijskim metodama (Hodrick-Prescott filter) izgladuju, čime se podaci "čiste" od tzv. šumova u podacima te se uklanjaju kratkoročne kolebljivosti. Rezultati analize pokazuju da na hrvatskom tržištu rada postoji vrlo značajan jaz između ponude i potražnje za radom, gdje potražnja za radnicima značajno nadmašuje ponudu koju radnici nude na tržištu, uz iznimku razdoblja zatvaranja gospodarstva tijekom 2020. godine. Stopa nezaposlenosti je na

* Izv. prof. dr. sc. Tomislav Globan, Ekonomski fakultet Sveučilišta u Zagrebu (e-mail: tgloban@efzg.hr).

¹ Inicijalna verzija ovog rada nastala je u sklopu projekta pod naslovom "Prijedlog koncepcije razvoja istraživačkog centra Hrvatskog zavoda za zapošljavanje s naglaskom na nove trendove u analitici radne snage" Ekonomskog fakulteta Sveučilišta u Zagrebu uz potporu Hrvatskog zavoda za zapošljavanje.

povijesno vrlo niskim razinama, dok je stopa slobodnih radnih mjesta natprosječno visoka. To upućuje na zaključak da je napetost (tenzija) na hrvatskom tržištu rada trenutno vrlo visoka. Aplikativna vrijednost ovog pokazatelja ogleda se u tome što tenzija na tržištu rada snažno korelira s budućim kretanjem stope rasta plaća u zemlji. Doprinos novih indikatora i vizualizacija trendova ogleda se u povećanju stupnja informiranosti javnosti i nositelja ekonomske politike o stanju, trendovima i perspektivama širokog broja pokazatelja tržišta rada u Republici Hrvatskoj. Ograničenja ovakvog načina vizualizacije trendova na tržištu rada su u tome što se izgladivanje vrši ispočetka svaki mjesec, stoga su grafički prikazi podložni reviziji jer se vrijednosti pokazatelja mogu u manjoj mjeri mijenjati. Također, s obzirom na to da se izgladivanjem podataka gube određene informacije na kraju vremenske serije podataka, potencijalno može biti potrebno između jedan do četiri mjeseca kako bi se pouzdano utvrdilo je li ciklus uistinu dosegao vrhunac ili dno.

Ključne riječi: tržište rada, vizualizacija, ponuda i potražnja za radom, napetost tržišta rada.

1. UVOD

Statistike tržišta rada predstavljaju ključan alat za znanstveno-istraživački rad, ali i definiranje ekonomskih politika. Podaci koji se pritom koriste proizlaze iz više izvora, kao što su ankete ili administrativne evidencije, a mogu se proizvesti prateći različite metodologije koje bi trebale biti usklađene s međunarodnim standardima. Prikladnost i pouzdanost statistika tržišta rada najvećim su dijelom determinirane karakteristikama korištenih izvora, što uključuje metodu kompilacije podataka, geografski obuhvat, referentno razdoblje te provjere konzistentnosti podataka (ILO, 2017).

Prema tumačenju Međunarodne organizacije rada (2017), istinska vrijednost statistika tržišta rada proizlazi iz njihova analitičkog potencijala. Pouzdane i pravodobne statistike tržišta rada igraju ključnu ulogu u stručnim i znanstvenim istraživanjima toga tržišta, kao i u formulaciji, implementaciji i evaluaciji ekonomskih politika. One predstavljaju temeljni input za rad studenata, znanstvenika, novinara i nositelja ekonomske politike, te podupiru donošenje odluka utemeljenih na dokazima. One su također vrlo koristan alat u komunikaciji pitanja vezanih za tržište rada prema javnosti, kao i informiranja javnosti o aktualnim trendovima na tom tržištu. S tim u

vezi, način na koji se statistike tržišta rada prezentiraju prema javnosti ima vrlo značajan utjecaj na to kako će one biti primljene i hoće li biti shvaćene (ILO, 2017).

Cilj ovog rada je unaprijediti postojeću prezentaciju aktualnih trendova na hrvatskom tržištu rada, koji su se do sada temeljili uglavnom na statičkim grafičkim prikazima, kroz nove, vizualno atraktivne, dinamičke i interaktivne grafičke prikaze i indikatore. U radu se iznose dva prijedloga takvih unaprijeđenja: i) Dinamička vizualizacija stanja na tržištu rada kroz vrijeme i kroz različite poslovne cikluse; ii) Izrada Semafora tenzije tržišta rada koji predstavlja procjenu ponude i potražnje za radom u Republici Hrvatskoj te dinamički prikaz njihove usklađenosti kroz vrijeme. Doprinos ovih novih indikatora i vizualizacija trendova ogleda se u povećanju stupnja informiranosti javnosti i nositelja ekonomske politike o stanju, trendovima i perspektivama širokog broja pokazatelja tržišta rada u Republici Hrvatskoj.

Rad je strukturiran na sljedeći način. Drugo poglavlje donosi dinamičku vizualizaciju stanja na tržištu rada kroz vrijeme i različite poslovne cikluse. Riječ je o lako razumljivom i interaktivnom mjesečnom prikazu cikličkih kretanja različitih varijabli hrvatskog tržišta rada iz mjeseca u mjesec kroz faze poslovnog ciklusa. Treće poglavlje bavi se izradom novog indikatora – Semafora tenzije tržišta rada. Kroz navedeni indikator vrši se procjena ponude i potražnje za radom u Republici Hrvatskoj te se dinamički prikazuje usklađenost ponude i potražnje na tržištu rada kroz vrijeme. Četvrto poglavlje iznosi zaključna razmatranja.

2. DINAMIČKA VIZUALIZACIJA TRENDOVA NA TRŽIŠTU RADA KROZ VRIJEME I POSLOVNE CIKLUSE

2.1. Konceptualne pretpostavke dinamičke vizualizacije indikatora tržišta rada


Tržište rada u Hrvatskoj, kao i svugdje u svijetu, obilježavaju ciklička kretanja. To znači da se pokazatelji toga tržišta kroz godine kreću sinusoidno, u više ili manje pravilnim "valovima" koji imaju svoj uzlaznu putanju, vrhunac, silaznu putanju, dno, i tako iznova. U Hrvatskoj se grafičke analize trendova na tržištu rada u pravilu svode na statičan i dvodimenzionalan prikaz vremenskih serija pojedinih pokazatelja tržišta

rada – npr. stope nezaposlenosti, stope zaposlenosti, bruto i neto plaća, stope slobodnih radnih mjesta i dr.

Problem ovakvog pristupa je što su navedeni pokazatelji obilježeni velikom kolebljivošću u kratkom roku te rast nekog od pokazatelja ne mora značiti zaokret u ciklusu tržišta rada, već biti samo kratkoročna promjena koja iščezava nakon mjesec ili dva. Dinamički prikazi koji će ovdje biti predstavljeni na jednostavan i lako razumljiv način opisuju položaj i dinamiku kretanja glavnih pokazatelja hrvatskog tržišta rada kroz četiri faze poslovnog ciklusa iz mjeseca u mjesec. S obzirom na to da se pokazatelji temelje na indikatorima visoke frekvencije objave, prikazi se mogu ažurirati na mjesečnoj bazi.

Četiri kvadranta na grafikonu opisuju četiri faze ciklusa na tržištu rada u odgovarajućim bojama (Slika 1.). Cikličnim kretanjem po kvadrantima koordinatnog sustava u smjeru obrnutom od kazaljke na satu, ovi pokazatelji nam govore nalaze li se pojedini indikatori hrvatskog tržišta rada na razinama iznad ili ispod svog dugogodišnjeg prosjeka, kreću li se u pozitivnom ili negativnom smjeru te gdje se nalaze i koliko su daleko točke preokreta iz faze u fazu. Vizualizacije se baziraju na desezoniranim podacima, stoga sezonska kretanja ne igraju ulogu u prolasku indikatora kroz faze ekonomskog ciklusa.

Slika 1. Kretanja indikatora na tržištu rada kroz četiri faze poslovnog ciklusa



Izvor: izrada autora.

Četiri kvadranta na grafikonu opisuju četiri faze ciklusa indikatora tržišta rada:

- **ekspanzija** (gornji desni kvadrant)
- **usporavanje** (gornji lijevi kvadrant)
- **recesija** (donji lijevi kvadrant)
- **oporavak** (donji desni kvadrant).

Ova klasifikacija prati uvriježene konvencije među ekonomistima prilikom definiranja faza poslovnih ciklusa i nudi jednostavnu i jasnu metodu objašnjavanja kretanja ekonomskih indikatora tijekom ciklusa.

Jednim pogledom na grafikon, čitatelj se istodobno upoznaje s čak četiri bitne informacije o tržištu rada u Hrvatskoj. Ako je riječ o stopi nezaposlenosti, čitatelj iz grafikona saznaje: (1) da li se nezaposlenost u Hrvatskoj trenutno kreće ispod ili iznad svoga povijesnog prosjeka, (2) koliko jako je taj odklon od prosjeka izražen, (3) da li aktualna nezaposlenost raste ili pada i (4) koliko brzo.

Uz to, grafikoni su vrlo intuitivni jer se tzv. točke preokreta lako uočavaju. Naime, vrhunci poslovnog ciklusa nalaze se na gornjem središnjem dijelu grafikona (okomita os koja razdvaja fazu ekspanzije od faze usporavanja), dok se dna poslovnog ciklusa nalaze na donjem središnjem dijelu grafikona (okomita os koja razdvaja fazu recesije od faze oporavka). Središnja vodoravna os predstavlja prosječne vrijednosti indikatora u analiziranom razdoblju.

2.2. Vizualizacija trendova na hrvatskom tržištu rada

Na Slici 2. prikazan je dinamički grafikon trendova na tržištu rada u Republici Hrvatskoj po zadnje dostupnim podacima u trenutku pisanja ovog rada (srpanj 2021.). Vizualizacija uključuje šest varijabli hrvatskog tržišta rada:

- 1) Broj zaposlenih
- 2) Stopa registrirane nezaposlenosti
- 3) Nominalne bruto plaće
- 4) Realne bruto plaće
- 5) Nominalne neto plaće
- 6) Realne neto plaće.

Sve varijable su iskazane kao godišnje stope rasta indikatora u odnosu na isti mjesec prethodne godine. Razdoblje obuhvaćeno analizom počinje od veljače 2006., a završava sa srpnjem 2021. godine. Izvor podataka je Državni zavod za statistiku. S obzirom na tiskani format izvještaja, dinamički prikazi dostupni su *online* na poveznici <https://charteca.blob.core.windows.net/pubs/btZttgCB8pUXq79R>. Na dnu grafikona pomicanjem *slidera* može se odabrati razdoblje za koje se želi vidjeti stanje trenda. Na vrhu grafikona mogu se uključivati ili isključivati prikazi pojedinih indikatora na grafičkom prikazu.

Slika 2. svjedoči kako se većina indikatora hrvatskog tržišta rada prema zadnje dostupnim podacima u trenutku pisanja ovog izvještaja nalazi u fazi **ekspanzije**. Na primjeru bruto i neto plaća, to znači da plaće rastu po stopama iznad dugogodišnjeg prosjeka (2006. – 2021.), a te stope rasta imaju trend rasta, tj. ubrzavaju. Realne bruto plaće nalazile su se relativno blizu okomite osi, što znači da su vjerojatno vrlo blizu svome vrhuncu rasta. U ovoj su fazi uvjeti na tržištu rada iznimno povoljni, BDP raste, mogućnosti za pronalazak posla su visoke, a plaće zaposlenima rastu zbog jake pregovaračke moći sindikata. U prethodnom je ciklusu vrhunac uvjeta na tržištu rada u kojem je nezaposlenost najbrže padala zabilježen u prosincu 2007. – nedugo prije propasti Lehman Brothersa i početka globalne financijske krize.


Zanimljivo je i primijetiti da su se i stopa rasta zaposlenosti i promjena nezaposlenosti u srpnju 2021. još uvijek nalazile u fazi **oporavka**, što znači da je trend u njihovim promjenama još uvijek negativan u odnosu na višegodišnji prosjek, ali uz trend poboljšanja. U početku ove faze uvjeti na tržištu rada još su uvijek teški, BDP se još uvijek ne mora nužno povećavati, ali loši trendovi su zaustavljeni te sa svakim dodatnim mjesecom građani mogu postati optimističniji glede pronalaska posla, a pregovaračka moć sindikata jača. Nezaposlenost je u srpnju 2021. bila na samom rubu prelaska u fazu ekspanzije, što znači da su trenutne stope po kojima se nezaposlenost smanjuje vrlo blizu tome da budu iznad višegodišnjeg prosjeka uz trend daljnjeg ubrzanja tog smanjenja. Kao što je vidljivo na Slici 2., zaposlenost nešto kaska za nezaposlenošću, no valja napomenuti da se metodologija obračunavanja broja zaposlenih od strane Državnog zavoda za statistiku u više navrata mijenjala prethodnih godina, što implicira da je stopa nezaposlenosti vjerojatno pouzdaniji podatak o stanju tržišta rada u Hrvatskoj.

Nakon što nezaposlenost počne rasti, a zaposlenost i plaće padati, uvjeti na tržištu rada iz faze usporavanja prelaze u fazu **recesije**. Nju obilježava najgora moguća kombinacija uvjeta na tržištu rada – rast razine nezaposlenosti uz trenda ubrzanja njezina rasta, sve u uvjetima pada BDP-a i vrlo slabe pregovaračke moći sindikata gdje često dolazi i do pada plaća zaposlenima. Ova agonija na hrvatskom tržištu rada u prethodnom ciklusu dogodila se u dva navrata (recesija s dvostrukim dnom), sve dok u veljači 2013. rast nezaposlenosti nije dosegao svoj vrhunac, a uvjeti na tržištu rada – dno. Na Slici 3. prikazano je stanje na tržištu rada u Hrvatskoj u kolovozu 2009. gdje su svi indikatori bili u fazi recesije. Posljednja faza recesije na tržištu rada trajala je najkraće do sada – kraće od godine dana i bila je

izazvana zatvaranjem gospodarstva i gubitkom radnih mjesta uslijed krize izazvane virusom SARS-Cov-2.

Slika 2. Dinamička vizualizacija trendova na tržištu rada – srpanj 2021.


TRŽIŠTE RADA U REPUBLICI HRVATSKOJ



Napomena: dinamički prikazi dostupni su na poveznici
<https://charteca.blob.core.windows.net/pubs/btZttgCB8pUXq79R>

Izvor: izrada autora na temelju podataka DZS-a (2021).

Slika 3. Dinamička vizualizacija trendova na tržištu rada – kolovoz 2009.




Napomena: dinamički prikazi dostupni su na poveznici
<https://charteca.blob.core.windows.net/pubs/btZttgCB8pUXq79R>
 Izvor: izrada autora na temelju podataka DZS-a (2021).

2.3. Metodološke napomene

Prije same dinamičke vizualizacije, bilo je potrebno izvršiti pripremu podataka za analizu. U prvom se koraku podaci desezoniraju metodom Census X12 kako bi se iz podataka isključio utjecaj sezonskih kretanja na tržištu rada koja su u Hrvatskoj izrazito prisutna. Potom se podaci ekonometrijskim metodama (Hodrick-Prescott filter) izgladuju, čime se podaci "čiste" od tzv. šumova u podacima te se uklanjaju kratkoročne kolebljivosti (Slika 4.).

Slika 4. Stopa nezaposlenosti – prije i nakon izgladivanja




Izvor: izračun autora na temelju podataka DZS-a (2021).

Potom se tako dobivena izgladena serija (stopa rasta) standardizira na način da joj prosječna vrijednost postaje jednaka nuli, a standardna devijacija (prosječno odstupanje od prosjeka) jednaka jedinici. Vrijednosti razina stavljaju se na okomitu os, dok se mjesečna promjena izgladene serije stavlja na horizontalnu os.

Time se kreira vizualna atraktivnost grafikona gdje kretanje po grafikonu automatski postaje kružno u smjeru obrnutom kazaljke na satu, kroz četiri

kvadranta koji odgovaraju četirima fazama ekonomskog ciklusa. Slika 5. prikazuje godišnju promjenu u stopi nezaposlenosti te izgladenu trend seriju te promjene koja se vizualizira na grafičkom prikazu.

Slika 5. Promjena stope nezaposlenosti u Hrvatskoj



Izvor: izrada autora na temelju podataka DZS-a (2021).

Neka od ograničenja ovakvog načina vizualizacije trendova na tržištu rada su u tome što se izgladivanje vrši ispočetka svaki mjesec, s objavom svakoga novog dostupnog podatka, stoga su grafički prikazi podložni reviziji jer se vrijednosti pokazatelja mogu u manjoj mjeri mijenjati. Također, s obzirom na to da se izgladivanjem podataka gube određene informacije na kraju vremenske serije podataka, potencijalno može biti potrebno između jedan do četiri mjeseca kako bi se pouzdano utvrdilo je li ciklus uistinu dosegao vrhunac ili dno.

Ovaj ugrađeni vremenski odmak negativna je strana izgladivanja podataka, no s druge strane, bez izgladivanja u podacima bi bio prisutan poprilično velik "šum" budući da rast ili pad vrijednosti indikatora može biti slučajnog i kratkotrajnog karaktera te ne predstavlja garanciju da je došlo do preokreta na tržištu rada. Također, bez izgladivanja podataka ne bi bilo moguće dobiti

ovako jasno i vizualno atraktivno cikličko kretanje indikatora kroz četiri faze ekonomskog ciklusa te bi kratkoročne varijacije sirovih podataka zamaglile uvid u pravo stanje ciklusa. Rizik od iznenađujućih revizija podataka može se dodatno smanjiti paralelnim proučavanjem većeg broja sektorskih indikatora. Primjerice, ako se više pokazatelja tržišta rada nalazi blizu linije koja razdvaja fazu ekspanzije i fazu usporavanja, to bi mogao biti znak da je točka zaokreta na tržištu rada već prijedena ili je vrlo blizu.

3. SEMAFOR TENZIJE TRŽIŠTA RADA

U ovom poglavlju kreira se novi indikator stanja na tržištu rada u Hrvatskoj. Riječ je o Semaforu tenzije tržišta rada koji predstavlja grafički prikaz (ne)usklađenosti ponude i potražnje za radom, tzv. napetosti tržišta rada u Hrvatskoj. Riječ je o svojevrsnoj dinamičkoj derivaciji Beveridgeove krivulje, koju su prvi izradili Dow i Dicks-Mireaux (1958). Tenzija tržišta rada rezultat je balansiranja između potražnje za radom od strane poduzeća i raspoložive ponude rada od strane radnika. Stupanj tenzije može se izračunati pomoću stope nezaposlenosti kao pokazatelja veličine ponude rada, te udjelom slobodnih i raspoloživih radnih mjesta u ukupnom broju radnih mjesta u zemlji kao mjere potražnje za radom.


Tenzija na tržištu rada raste ako je, primjerice, potražnja za radnicima visoka, a nezaposlenost, kao mjera ponude rada, niska. Ako dođe do smanjenja potražnje za radnicima, tenzija će se na tržištu rada smanjiti, čak i ako nezaposlenost ostane niska. Aplikativna vrijednost ovog pokazatelja ogleda se u tome što tenzija na tržištu rada snažno korelira s budućim kretanjem stope rasta plaća u zemlji. Kada je tenzija na tržištu rada visoka, plaće će značajno rasti zbog povoljnijega pregovaračkog položaja sindikata i radnika, dok u uvjetima padajuće tenzije, plaće će rasti znatno sporije.

S obzirom na međudnos između ponude i potražnje, semafor tenzije tržišta rada pokazuje u kojoj od četiri faze se tržište rada trenutno nalazi, krećući se u smjeru kazaljke na satu (Slika 6.):

- i. **Faza napetosti tržišta rada** – potražnja za radom je iznadprosječna, a ponuda rada niska i nedovoljna
- ii. **Faza opadajuće napetosti** – potražnja za radom je pala ispod prosjeka, a ponuda rada je još uvijek niska

- iii. **Faza labavosti tržišta rada** – potražnja za radom je još uvijek ispod prosjeka, a ponuda rada je visoka
- iv. **Faza rastuće napetosti** – potražnja za radom je narasla iznad prosjeka, ali tržište rada još nije napeto jer je ponuda rada (nezaposlenost) i dalje relativno visoka.

Slika 6. Četiri faze (ne)usklađenosti ponude i potražnje na tržištu rada




Izvor: izrada autora prema CBS (2012).

Semafor se bazira na desezoniranim podacima, stoga sezonska kretanja ne igraju ulogu u definiranju stupnja (ne)usklađenosti ponude i potražnje na tržištu rada. Podaci se potom izgladuju Hodrick-Prescottovim filterom ($\lambda = 500$), čime se podaci "čiste" od tzv. šumova u podacima te se uklanjaju kratkoročne kolebljivosti.

Interaktivni grafikon prikazuje potražnju za radnicima i ponudu rada kao standardizirane devijacije od prosječnih vrijednosti u cjelokupno analiziranom razdoblju (2004. – 2021.). Drugim riječima, vrijednost 0 označava prosječnu stopu nezaposlenosti (okomita os), odnosno prosječnu stopu slobodnih radnih mjesta (vodoravna os). Pozitivne vrijednosti označavaju natprosječno nisku stopu nezaposlenosti te natprosječno visoku stopu slobodnih radnih mjesta, dok negativne vrijednosti znače obratno.

Slika 7. pokazuje kako se hrvatsko tržište rada od travnja 2016. do danas nalazi u fazi napetog tržišta rada, uz iznimku razdoblja od veljače do listopada 2020. kada se nalazilo u fazi opadajuće napetosti. Ova kratkoročna promjena trenda bila je rezultat blagog rasta nezaposlenosti, ali i značajnijeg pada broja slobodnih radnih mjesta uslijed mjera zatvaranja zbog pandemije virusa SARS-Cov-2. Budući da se otvaranjem gospodarstva tržište rada vrlo brzo vratilo na predpandemijske razine, tenzija na tržištu rada u srpnju 2021. bila je visoka jer se istodobno nalazi u fazi iznadprosječno visoke stope slobodnih radnih mjesta te vrlo niske stope nezaposlenosti. To znači da je potražnja za radnicima daleko veća od ponude rada od strane radnika. U takvim uvjetima, pritisak na rast plaća je vrlo snažan, što se potvrđuje recentnim kretanjima razine plaća u Hrvatskoj koje kontinuirano rastu.

Slika 7. Semafor tenzije tržišta rada



Napomena: dinamički prikazi dostupni su na poveznici <https://plot.ly/~tgloban/109/>


Izvor: izrada autora na temelju podataka HZZ-a (2021) i DZS-a (2021).

Na grafikonu je vidljivo da je hrvatsko tržište rada u posljednjih 17 godina prošlo kroz sve četiri faze (ne)usklađenosti ponude i potražnje za radom. Tako je, primjerice, Hrvatska gotovo pet godina provela u fazi labavog tržišta rada. Naime, od srpnja 2009. do travnja 2014. stopa slobodnih radnih mjesta bila je ispodprosječno niska, dok je nezaposlenost istovremeno dosežala natprosječno visoke stope. U takvim recesijskim uvjetima, rast plaća bio je izuzetno ograničen, a u nekim sektorima plaće su i padale.


Interaktivni Semafor je dostupan *online* na poveznici <https://plot.ly/~tgloban/109/>. Grafikon je interaktivan te se prelaskom mišem preko točaka otkriva razdoblje na koje se pojedina točka odnosi.

Slika 8. Stopa nezaposlenosti i stopa slobodnih radnih mjesta (desna os) u RH

(a) sezonski prilagođene, neizgladene serije



(b) izgladene serije



Izvor: izrada autora na temelju podataka HZZ-a (2021) i DZS-a (2021).

Slika 8. daje dvodimenzionalan prikaz serija ponude rada od strane radnika mjerenu stopom nezaposlenosti te potražnje za radnicima u Hrvatskoj mjerenu stopom slobodnih radnih mjesta. Vidljivo je da je u posljednjih pet godina vrlo značajan jaz između ponude i potražnje za radom, gdje potražnja za radnicima značajno nadmašuje ponudu koju radnici nude na tržištu, uz iznimku razdoblja zatvaranja gospodarstva tijekom 2020. godine. Stopa nezaposlenosti je na povijesno vrlo niskim razinama, dok je stopa slobodnih radnih mjesta natprosječno visoka. To upućuje na zaključak da je napetost (tenzija) na hrvatskom tržištu rada trenutno vrlo visoka.

4. ZAKLJUČAK

Cilj ovog rada bio je unaprijediti i dinamizirati vizualizaciju trendova na tržištu rada Republike Hrvatske. Te vizualizacije su se do sada temeljile uglavnom na statičkim grafičkim prikazima, a u ovom radu iznose se prijedlozi za njihovo unaprjeđenje kroz nove, vizualno atraktivne, dinamičke i interaktivne grafičke prikaze i indikatore.

U radu se iznose dva prijedloga takvih unaprjeđenja: i) *Dinamička vizualizacija stanja na tržištu rada kroz vrijeme i kroz različite poslovne cikluse*; ii) *Izrada novog indikatora – Semafora tenzije tržišta rada* – koji predstavlja procjenu ponude i potražnje za radom u Republici Hrvatskoj te dinamički prikaz njihove usklađenosti kroz vrijeme.

Razvojem ove skupine dinamičkih indikatora ispravljaju se nedostaci postojećih vizualizacija indikatora tržišta rada u Hrvatskoj. Navedeni indikatori i vizualizacije trendova povećat će stupanj informiranosti javnosti i nositelja ekonomske politike o stanju, trendovima i perspektivama širokog broja pokazatelja tržišta rada u RH. Ovaj rad valja promatrati kao temelj za kontinuirano unaprjeđenje standarda napredne dinamičke vizualizacije trendova na hrvatskom tržištu rada kao i izrade novih, odnosno poboljšavanja postojećih, indikatora.

U tom kontekstu, neki od prijedloga za buduće iskorake uključuju daljnje unaprjeđenje geografske vizualizacije trendova na hrvatskom tržištu rada kroz kombinaciju dinamičkog (temporalnog) i prostornog pristupa, umjesto dosadašnjeg statičkog i jednodimenzionalnog pristupa. Riječ je o interaktivnim mapama Republike Hrvatske s temporalnom komponentom i mogućnošću prikaza kroz više točaka u vremenu. Navedeno zahtijeva i napredniju razinu programiranja prilikom izrade. Nadalje, moguće je

napraviti grafikon "više rezolucije" gdje bi se umjesto cijele Hrvatske promatrala napetost tržišta po županijama, a moguće je promatrati i napetost tržišta po NKD djelatnostima gdje bi se vidjelo kako se situacija razlikuje od sektora do sektora te postoje li sektorske heterogenosti po pogledu trendova na tržištu rada. Spomenute iteracije i prilagodbe indikatora omogućavaju fleksibilnost nužnu kako bi se izvještavanje prilagodilo potrebama nositelja ekonomske politike, koje se razlikuju od potreba opće javnosti.

Nadalje, dinamički indikatori nudili bi više korisnih informacija ako bi se stavili u kontekst ostalih zemalja Europske unije. S obzirom na snažnu ekonomsku povezanost i rastuću integriranost hrvatskih radnika u tržišta rada drugih zemalja članica EU-a, usporedna komparativna vizualizacija trendova na hrvatskom i europskim tržištima rada bila bi vrijedan input u predviđanju budućih trendova migracija hrvatskih stanovnika, što je temeljan preduvjet za donošenje adekvatnih politika iz područja tržišta rada.

Postoji prostor i za promatranje cikličke dinamike većeg broja indikatora od onoga što je trenutno slučaj, kao i za detaljniji prikaz statistika na mikro-razini. Primjerice, vizualizirati dinamičke trendove na tržištu rada s obzirom na spol, dob, stupanj obrazovanja pojedinaca, vrstu radnog odnosa, pripadnost lokalnim jedinicama te kategorije djelatnosti prema NKD-u i sl. Uz dostupnost podataka na mikrorazini, moguće je provesti i cost-benefit analizu uspješnosti određenih programa poput Stručnog osposobljavanja bez zasnivanja radnog odnosa, aktivnih mjera zapošljavanja i drugih politika na tržištu rada.

LITERATURA

Centraal Bureau voor de Statistiek (2012). *The Labour Market Tension Meter*. Dostupno na: <https://www.cbs.nl/en-gb/background/2012/07/the-labour-market-tension-meter> [pristupljeno: 19. 12. 2019.].

Dow, J. C. R. i Dicks-Mireaux, L. A. (1958). The Excess Demand for Labour. A Study of Conditions in Great Britain, 1946-56. *Oxford Economic Papers*, 10(1), 1-33.

Državni zavod za statistiku (2021). *Osnovni pokazatelji*. Dostupno na: https://www.dzs.hr/Hrv_Eng/Pokazatelji/Osnovni%20pok.xlsx [pristupljeno: 27. 8. 2021.].

Hrvatski zavod za zapošljavanje (2021). *Statistika tržišta rada – otvoreni podaci*. Dostupno na: <https://www.hzz.hr/statistika/> [pristupljeno: 3. 9. 2021.].

International Labour Organization (2017). *Visualizing Labour Markets: A Quick Guide to Charting Labour Statistics*. ILO: Ženeva, Švicarska.

MEASURING AND VISUALISING THE TENSION IN THE CROATIAN LABOUR MARKET

Abstract

The aim of this paper is to quantify the relationship between the supply and demand in the Croatian labour market and improve the existing presentation of current trends in the labour market through new, visually attractive, dynamic and interactive graphs and indicators. The paper presents two proposals for such improvements: i) Dynamic visualisation of the situation in the labour market over time and through different business cycles; ii) Development of a new indicator - the Labour Market Tension Scoreboard - which represents an assessment of labour supply and demand in the Republic of Croatia and a dynamic display of their compliance over time. From the methodological point of view, first the data are seasonally adjusted by the Census X12 method in order to exclude from it the influence of seasonal movements on the labour market, which are extremely present in Croatia. Then the data are smoothed by econometric methods (Hodrick-Prescott filter), which "cleans" the data from the so-called noise in it and removes short-term volatility. The results of the analysis show that in the Croatian labour market there is a very significant gap between supply and demand for labour, where demand for workers significantly exceeds the supply offered by workers in the market, with the exception of the 2020 lockdown period. The unemployment rate is at historically very low levels, while the job vacancy rate is above average. This suggests that the tension in the Croatian labour market is currently very high. The contribution of these new indicators and the visualisation of trends are reflected in the increase in the level of information communicated to the public and economic policy makers about the state, trends and perspectives of a wide range of labour market indicators in the Republic of Croatia. The limitations of visualising labour market trends in such way are that time series smoothing is done from scratch every month, so the graphs are subjected to revision because the values of the indicators may change to a lesser extent. Also, since data smoothing loses some information at the end of time series, it can potentially take between one to four months to reliably determine if a cycle has indeed peaked or bottomed out.

Keywords: labour market, visualisation, supply and demand for labour, labour market tension.

JEL klasifikacija: J20, J21, J650, H25
Pregledni rad

UTJECAJ MJERE "OČUVANJE RADNIH MJESTA" NA ISPLATE RADNIČKIH TRAŽBINA U SLUČAJU STEČAJA ILI BLOKADE RAČUNA POSLODAVCA

Ivan Madunić*

SAŽETAK

Ono što je bilo zajedničko ovoj pandemiji je neizvjesnost utjecaja na gospodarska kretanja. Nikada u povijesti svjetska ekonomija nije stala kao u doba pandemije COVID-19.

Neizvjesnost utjecaja proizlazila je iz najmanje dva razloga. Prvi razlog bila je nemogućnost procjene vremena pronalaska odgovarajućeg cjepiva i druga neizvjesnost nadovezala se na prvu, a to je, ovisno o vremenu trajanja, koliki će biti utjecaj pandemije na pojedine sastavnice gospodarstva.

Jedan od najvećih negativnih kratkoročnih utjecaja očekivao se u području povećanja broja nezaposlenih osoba zbog nedostatka likvidnosti u gospodarstvu, blokade poslovnih računa poduzeća i otvaranja stečajnih postupaka nad poduzećima. Takav nepovoljni scenarij izvršio bi ogroman pritisak na javne financije koji bi se ogledao u smanjenju državnih prihoda i povećanju izdvajanja za prava radnika sukladno Zakonu o tržištu rada (Narodne novine, br. 118/18 i 30/20) i Zakonu o osiguranju radničkih tražbina (Narodne novine, br. 70/17).

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

Cilja rada je prikazati kako su Vladine Mjere za očuvanje radnih mjesta utjecale na isplate radničkih tražbina u slučaju stečaja ili blokade računa poslodavca. U radu će se analitički, za dulje razdoblje, prikazati isplate radničkih tražbina, broj blokiranih poslodavaca i broj poslodavaca nad kojima je otvoren stečajni postupak u vrijeme trajanja pandemije COVID-19. Utvrdit će se u kojem obujmu su Mjere očuvanja radnih mjesta imale utjecaj na isplate radničkih tražbina putem Agencije za osiguranje radničkih tražbina te će se procijeniti priljev zahtjeva radnika za ostvarivanje prava u slučaju stečaja ili blokade računa poslodavca.

U svrhu prikupljanja informacija konzultirane su internetske stranice javnopravnih tijela Republike Hrvatske, Hrvatskog zavoda za zapošljavanje, Agencije za osiguranje radničkih tražbina, Financijske agencije, Državnog inspektorata i druge. U znanstvenom istraživanju, oblikovanju i prezentiranju rezultata istraživanja u ovom radu koristit će se, u odgovarajućim kombinacijama: metoda deskripcije i komparacije, metode analiza i sinteze, komparativna metoda, induktivna i deduktivna metoda i metode procjene.

Ključne riječi: radnička tražbina, očuvanje radnih mjesta, pandemija COVID-19.

1. UVOD

Prošlo je nešto više od godinu i pol dana kada se potkraj 2019. godine novi koronavirus pojavio u Kini, a zatim ubrzo proširio i na ostatak svijeta. Uslijed nezaustavljivog širenja respiratorne bolesti nazvane COVID-19 koju uzrokuje ovaj virus, Svjetska zdravstvena organizacija je 11. ožujka 2020. godine proglasila pandemiju. Svjetsko gospodarstvo je neočekivano zaustavljeno. Nije bilo dovoljno parametara na osnovi kojih bi se prognozirala šteta koja će nastati za globalnu ekonomiju. Ono u čemu su se analitičari ubrzo usuglasili je bila procjena nepovoljnog utjecaja na broj zaposlenih radnika, odnosno očekivanja na tržište rada bila su negativna, te je ukazano na potrebu brzog djelovanja Vlada država u cilju ublažavanja negativnih posljedica na tržište rada (Adams-Prassl i drugi, 2020; Hershbein i Holzer, 2021; Andreosso-O'Callaghan, Moon i Sohn, 2021). U proljetnoj prognozi za 2020. godinu Europska komisija za Europsku uniju procijenila je stopu nezaposlenosti 9,0%, dok je za Republiku Hrvatsku stopa nezaposlenosti procijenjena na 10,20% (Europska komisija, 2020). Zahvaljujući pravodobnim mjerama Vlade Republike Hrvatske u potpori

poslodavcima da zadrže radnike i povoljnijim kretanjima u hrvatskom gospodarstvu, u svojim proljetnim prognozama 2021. godine Europska komisija reducirala je očekivanu stopu nezaposlenosti za Republiku Hrvatsku za 2021. godinu na razinu od 7,2%, dok je za 2022. godinu stopa nezaposlenosti za Republiku Hrvatsku procijenjena na 6,6% (Europska komisija, 2021).

Epidemija koronakrize različito je pogađala pojedine skupine zaposlenih radnika s obzirom na obrazovnu dobnu i spolnu strukturu. Fabrizio, Diego i Tavares (2021) u svom istraživanju koje su proveli na populacijskim skupinama žena i muškaraca s mlađom djecom i bez djece pokazala su da žene koje imaju mlađu djecu u osnovnim školama, nakon zatvaranja škola češće dobivaju otkaz s posla i teže pronalaze posao od ostalih žena i muškaraca sa ili bez male djece (Fabrizio, Diego i Tavares, 2021).

Kako bi se usporilo širenje epidemije, većina zemalja pribjeglja je mjerama izolacije različitog intenziteta. U Hrvatskoj je 16. ožujka 2020. godine obustavljen rad vrtića, škola i fakulteta, a nekoliko dana kasnije uvodi se potpuno obustavljanje svih aktivnosti koje nisu nužne. Iako su koristi tih mjera s epidemiološkog aspekta tada bile neupitne, one imaju dalekosežne štetne posljedice na gospodarstvo. Da bi se ublažio utjecaj pandemije na broj zaposlenih radnika, Vlada Republike Hrvatske je 17. ožujka 2020. godine donijela ukupno 66 mjera za pomoć gospodarstvu (Vlada Republike Hrvatske, 2020). Mjere za ublažavanje posljedica koronavirusa razvijaju se i unaprijeđuju, a jedna od najznačajnijih – kako po utjecaju na održivost poslovanja tvrtki tako i po troškovima implementacije za državu – je Potpora za očuvanje radnih mjesta u djelatnostima pogođenima koronavirusom (COVID-19) (Primorac, Šimović i Arčabić, 2020). Mjere koje je donijela Vlada RH imale su za cilj osigurati socijalni minimum za radnike i likvidnost za poduzeća da ne dođe do otpuštanja radnika, blokada računa i stečaja.

U slučajevima kada poduzeće završi u stečaju ili kada ne isplaćuje plaće radniku, uz ispunjavanje određenih preuvjeta, radnici su u mogućnosti putem Agencije za osiguranje radničkih tražbina (dalje u tekstu: AORT), a u skladu sa Zakonom o osiguranju radničkih tražbina (Narodne novine, br. 70/17, dalje u tekstu: Zakon) ostvariti isplatu određenih naknada koje im je ostao dužan njihov poslodavac.

U ovom radu analizirat će se podaci o visini isplate naknada radnicima iz Vladine mjere Potpora za očuvanje radnih mjesta u djelatnostima

pogođenima koronavirusom (COVID-19) (dalje u tekstu: Potpora), podaci iz Trgovačkih sudova o pokrenutim stečajnim postupcima te podaci iz Financijske agencije (dalje u tekstu: FINA) i AORT-a. Usporedbom podataka dužih razdoblja o isplatama radnicima putem AORT-a i otvorenim stečajnim postupcima s isplatama iz Vladinih mjera doći će se do zaključka o međusobnom odnosu tih aktivnosti.

2. POTPORE ZA OČUVANJE RADNIH MJESTA U DJELATNOSTIMA POGOĐENIMA KORONAVIRUSOM (COVID-19)

Na 55. sjednici Upravnog vijeća Hrvatskog zavoda za zapošljavanje (dalje u tekstu: HZZ) usvojene su izmjene i dopune Uvjeta i načina korištenja sredstava za provođenje mjera aktivne politike zapošljavanja (HZZ, 55. sjednica Upravnog vijeća, 2020). Predmetnim Izmjenama i dopunama dodana je nova mjera očuvanja radnih mjesta pod nazivom *Potpore za očuvanje radnih mjesta u djelatnostima pogođenima koronavirusom (COVID-19)*. Ova mjera uporište je imala u prethodno donesenom Zaključku Vlade RH o Prijedlogu mjera za pomoć gospodarstvu uslijed epidemije koronavirusa, od 17. ožujka 2020. godine (Vlada Republike Hrvatske, 2020). Obrazloženje za donošenje mjere od strane HZZ-a bilo je da s obzirom na stanje u gospodarstvu uvjetovano koronavirusom (COVID-19), HZZ svoje aktivnosti usmjerava na očuvanje radnih mjesta u djelatnostima/sektorima kojima je zbog posebne okolnosti uvjetovane koronavirusom (COVID-19) narušena gospodarska aktivnost. Sektori, odnosno djelatnosti koje je u prvoj fazi obuhvatila ova mjera bili su:

- prijevoz i skladištenje,
- djelatnost pružanja smještaja te pripreme i usluživanja hrane i pića,
- radno intenzivne djelatnosti unutar prerađivačke industrije – tekstil, odjeća, obuća, koža, drvo i namještaj,
- poslodavci koji ne mogu obavljati djelatnost sukladno Odlukama Stožera civilne zaštite (nacionalnog, županijskog, jedinica lokalne samouprave),
- drugi poslodavci koji mogu dokazati utjecaj posebnih okolnosti.

Mjera Potpora za očuvanje radnih mjesta u djelatnostima pogođenima koronavirusom (COVID-19) propisivala je isplatu 3.250 kuna mjesečno po

radniku koji radi u punom radnom vremenu i 1.625 kuna mjesečno po radniku koji radi u nepunom radnom vremenu, odnosno, razmjerni iznos broja odrađenih dana ako je manje od mjesec dana. Propisano razdoblje trajanja Potpore bilo je od 1. ožujka 2020. godine i dalje, a najdulje do tri mjeseca.

2.1. Karakteristike Potpore za očuvanje radnih mjesta u djelatnostima pogođenima koronavirusom (COVID-19)

Cilj mjere Potpora za očuvanje radnih mjesta u djelatnostima pogođenima koronavirusom (COVID-19) je, kako joj i sam naziv govori, *očuvanje radnih mjesta*. Očekivano, najveće negativne posljedice epidemiološke mjere *zatvaranja gospodarstva* bile su na povećanje broja otpuštanja radnika u određenim sektorima gospodarstva. Gospodarska je aktivnost bila posebno narušena u djelatnostima pružanja smještaja te pripreme i usluživanja hrane i pića, djelatnostima prijevoza i skladištenja, u radno-intenzivnim djelatnostima unutar prerađivačke industrije (tekstil, odjeća, obuća, koža, drvo i namještaj) te u djelatnostima trgovine, uslužnih djelatnosti i održavanja sportskih i kulturnih događaja. HZZ je gore nabrojenu ciljanu skupinu nazvao *Prihvatljivi poslodavci i sektori* (HZZ, 55. sjednica Upravnog vijeća, 2020). Ciljana skupina dodatno je proširivana ili sužavana na sljedećim sjednicama Upravnog vijeća HZZ-a, a sve u ovisnosti o gospodarskim kretanjima i epidemiološkim mjerama u pojedinim djelatnostima. Na 4. sjednici novog saziva Upravnog vijeća HZZ-a od 25. lipnja 2020. godine definirana je posebna ciljana skupina *poslodavci koji zapošljavaju manje od 10 radnika (mikro poduzetnici) iz sektora: Prerađivačka industrija: 10.71. Proizvodnja kruha; proizvodnja svježih peciva i sličnih proizvoda te kolača; 11.01. Destiliranje, pročišćavanje i miješanje alkoholnih pića; 32.99 Ostala prerađivačka industrija, d. n.*, dok je na 7. sjednici Upravnog vijeća HZZ-a od 29. srpnja 2020. godine kao ciljana posebna skupina dodano i očuvanje radnih mjesta *u zaštitnim radionicama, integrativnim radionicama i radnim jedinicama za zapošljavanje osoba s invaliditetom čija je djelatnost pogođena Koronavirusom (COVID-19)* (HZZ, 7. sjednica Upravnog vijeća, 2020). U prosincu 2020. godine Upravno vijeće HZZ-a na svojoj 13. sjednici ciljanu skupinu proširilo je na sve *poslodavce kojima je na bilo koji način ograničen rad Odlukama Stožera civilne zaštite (nacionalnog, županijskog, jedinica lokalne samouprave) ili su poslovno povezani kao dobavljači s*

poslodavcima koji su zatvoreni Odlukom stožera (HZZ, 13. sjednica Upravnog vijeća, 2020).

Osim koronavirusa na ciljanu skupinu ove mjere utjecao je i potres na području Sisačko-moslavačke, Zagrebačke i Karlovačke županije, tako da je na 15. sjednici Upravnog vijeća HZZ-a proširen i naziv mjere pa je od 8. siječnja 2021. godine mjera poznata kao *Potpore za očuvanje radnih mjesta u djelatnostima pogođenima koronavirusom (COVID-19) i posljedicama katastrofe uzrokovane potresom na području Sisačko-moslavačke, Zagrebačke i Karlovačke županije za siječanj – veljaču 2021* (HZZ, 15. sjednica Upravnog vijeća, 2021). Osnovni cilj mjere i dalje je ostao očuvanje radnih mjesta.

Ranije je rečeno da je na 55. sjednici Upravnog vijeća HZZ-a utvrđena visina potpore od 3.250 kuna mjesečno po radniku. Međutim već na 57. sjednici Upravnog vijeća HZZ-a visina potpore povećana je na 4.000 kuna po radniku za mjesec travanj i svibanj 2020. godine (HZZ, 57. sjednica Upravnog vijeća, 2020). Visina potpore od 4.000 kuna kasnije se nije mijenjala. Pravo na isplatu Potpore nisu mogli ostvariti vlasnici, suvlasnici, osnivači, članovi uprave, direktori, prokuristi i sl., *uz izuzeće poslodavaca kod kojih je zaposleno do 10 radnika i vlasnika obrta*. Ova odredba izuzeća dodatno je pojašnjena izmjenama kriterija na 56. sjednici Upravnog vijeća HZZ-a održanoj 25. ožujka 2020. godine, pri čemu je rečeno da izuzeće ne vrijedi za one poslovne subjekte koji imaju istog osnivača / vlasnika koji pojedinačno zapošljavaju manje od 10 radnika, a u ukupnom broju zaposlenih ima više od 10 radnika. Prema HZZ-u za takve poslodavce nije opravdano vršiti isplatu Potpore (HZZ, 56. sjednica Upravnog vijeća, 2020). Na ovoj sjednici Upravnog vijeća HZZ-a pojašnjen je i dodatni kriterij za nemogućnost korištenja Potpore, a koji će imati utjecaj na podnošenje zahtijeva prema AORT-u. Taj dodatni kriterij nemogućnosti dobivanja Potpore odnosi se na one poslodavce koji *nisu isplatili plaću/e za veljaču 2020. godine*. Ova odredba donesena je zato što na neisplatu plaće radnicima za veljaču nije utjecala pojava koronavirusa. Za poslodavce je sukladno Zakonu o radu (Narodne novine, br. 93/14, 127/17 i 98/19) propisana obveza isplate plaće, a Zakon o osiguranju radničkih tražbina (Narodne novine, br. 70/17) propisuje proceduru isplate plaće radnicima u slučajevima blokade računa poslodavca zbog neisplate plaće ili u slučajevima stečaja poslodavca.

HZZ je propisao da se Potpora ne odnosi na poslovne subjekte čiji su osnivači Republika Hrvatska, županije i jedinice lokalne samouprave i imaju vlasničke udjele od 25% ili više, uz izuzeće poslodavaca iz Sektora C: Prerađivačka industrija i Sektora I: Djelatnosti pružanja smještaja te pripreme i usluživanja hrane. Zabranjena je i kumulacija opravdanog troška iste namjene (trošak plaće) po različitim mjerama. Ostavljena je mogućnost poslodavcu da u mirovanje stavi mjeru Aktivne politike zapošljavanja za vrijeme korištenja Potpore, a da istekom razdoblja korištenja Potpore nastave u preostalom razdoblju koristiti mjeru Aktivne politike zapošljavanja.

Sljedeća karakteristika mjere bila je da poslodavci korisnici Potpore ne smiju uvoziti stranu radnu snagu niti zapošljivati nove radnike u razdoblju korištenja Potpore. Također, i poslodavcima koji su imali pad broja zaposlenih od 1. do 20. ožujka 2020. godine mogla se odobriti Potpora. Ovaj kriterij djelomično je izmijenjen na 57. sjednici Upravnog vijeća HZZ-a gdje je omogućeno poslodavcima koji su tijekom mjeseca ožujka (od 1.3. do 1.4.2020.) otpustili radnike da mogu koristiti ovu mjeru isključivo za radnike kojima je zadnji radni odnos završio kod istog poslodavca uz uvjet da ih je poslodavac ponovno prijavio u radni odnos (HZZ, 57. sjednica Upravnog vijeća, 2020). Ublažavanje ovog kriterija došlo je zato što su pojedini poslodavci otpustili radnike ne znajući da će Vlada RH tako brzo donijeti mjere za ublažavanje negativnih posljedica koronakrize. Vezano za otpuštanje radnika od 20. ožujka 2020. do dana predaje Zahtjeva za dodjelu Potpore, pravo na Potporu nisu imali poslodavci ako je pad broja zaposlenih veći:

- od 40% kod poslodavaca koji zapošljavaju do 10 radnika,
- od 20% za mala poduzeća,
- od 15% za srednja poduzeća,
- i 10% za velika poduzeća.

U izračun pada broja zaposlenih ne ulazi istek ugovora o radu na određeno vrijeme, odlazak radnika u mirovinu i otkaz uvjetovan skrivljenim ponašanjem radnika.

Potkraj proljeća 2020. godine epidemiološke mjere i mjere Vlade RH dovele su do otvaranja i većih aktivnosti u gospodarstvu, što je iziskivalo donošenje dodatnih kriterija isplate Potpore. Na 2. sjednici Upravnog vijeća HZZ-a od

28. svibnja 2020. godine (novi saziv Upravnog vijeća) usvojen je kriterij isplate potpore za svibanj za poslodavce koji su u svibnju 2020. godine imali pad prihoda za najmanje 50% u odnosu na svibanj 2019. godine. Za one poslodavce koji su poslovali kraće od 12 mjeseci kao dokaz pada prometa uzimala se usporedba prometa u svibnju 2020. godine u odnosu na veljaču 2020. godine (HZZ, 2. sjednica Upravnog vijeća, 2020), ovaj kriterij je dodatno izmijenjen na 9. sjednici Upravnog vijeća HZZ-a od 7. rujna 2020. godine, pri čemu je trebalo dokazati pad prihoda od 60% u mjesecu koji prethodi onome za koji se traži potpora u odnosu na isti mjesec 2019. godine (HZZ, 9. sjednica Upravnog vijeća, 2020). Zbog pozitivnih gospodarskih kretanja i nastojanjem da se pomogne djelatnostima čije je poslovanje i dalje ugroženo koronavirusom, Upravno vijeće HZZ-a u ožujku 2021. godine (HZZ, 19. sjednica Upravnog vijeća, 2021) visinu potpore od 4.000 kuna mjesečno po radniku dodatno je vezalo uz pad prihoda / primitaka, i to:

- od 40,00% do 44,99% – 2.000,00 kuna
- od 45,00% do 49,99% – 2.500,00 kuna
- od 50,00% do 54,99% – 3.000,00 kuna
- od 55,00% do 59,99% – 3.500,00 kuna
- od 60% i više – 4.000,00 kuna.

Obrazac Zahtjeva za dobivanje Potpore, procedura odobrenja te obveze poslodavca i HZZ-a detaljno su objavljene na stranici www.mjere.hr.

Kako bi se cijeli proces odvijao što brže i učinkovitije, HZZ je otvorio nekoliko kanala podnošenja Zahtjeva. Omogućeno je podnošenje Zahtjeva na online platformi, elektroničkom poštom ili u nadležnoj službi HZZ-a prema sjedištu poslodavca.


2.2. Struktura iznosa Potpore za očuvanje radnih mjesta

U ovom dijelu rada analizirat će se struktura isplate Potpore po broju radnika, iznosu Potpore i po veličini poduzetnika u mjesečnim razdobljima od ožujka 2020. godine zaključno do isplate Potpore za lipanj 2021. godine.

Na Grafikonu 1. vidljivo je da je najveći iznos Potpore isplaćen za mjesec travanj 2020. godine. Potporu je tada iskoristilo 581.300 radnika, a visina

isplaćene Potpore bila je 2.267.200 kuna. Otvaranjem pojedinih kategorija gospodarstva i poboljšanjem epidemiološke situacije, broj korisnika Potpore tijekom ljetnih mjeseci značajno je opao. Stabilizacija gospodarstva i zdravstvenog sustava dovela je do ukupnog smanjenja korisnika Potpore u drugom valu epidemije (kraj 2020. i početak 2021. godine). Iz grafikona je vidljivo i da je u svibnju 2020. godine isplaćen veći novčani iznos za manji broj korisnika nego u ožujku. Razlog većoj isplati je porast naknade sa 3.250 na 4.000 kuna.


Grafikon 1. Struktura iznosa Potpore prema broju radnika i visini isplate



Izvor: obrada prema podacima Hrvatskog zavoda za zapošljavanje.

Na Grafikonu 2. prikazana je struktura isplate Potpore prema broju radnika i veličini poduzetnika. Iz prikaza je uočljivo da je najveći iznos Potpore isplaćen mikro poduzetnicima koji zapošljavaju do 10 radnika. Također prema podacima HZZ-a i nominalno najveći broj korisnika Potpore su mikro poduzetnici.

Grafikon 2. Isplata Potpore prema veličini poduzetnika



Izvor: obrada prema podacima Hrvatskog zavoda za zapošljavanje.

3. OSIGURANJE RADNIČKIH TRAŽBINA

U ovom poglavlju pojasnit će se institut osiguranja radničkih tražbina i analizirat će se isplate obzirom na broj poslodavaca i broj radnika. Analiza će obuhvatiti razdoblje od 1. siječnja 2017. do 30. lipnja 2021. godine. Početak 2017. godine uzet je zato što je u to vrijeme rast gospodarstva bio pozitivan, još uvijek nije bilo nikakvih naznaka pandemije koronavirusa te se u tom razdoblju problemi u poslovanju poduzetnika mogu pripisati uglavnom tržišnim uvjetima.

3.1. Osiguranje radničkih tražbina

Institut osiguranja radničkih tražbina u hrvatsko zakonodavstvo uveden je 2003. godine kao dio pravne stečevine Europske unije i nastojanjem Republike Hrvatske da postane punopravna članica Europske unije. Pod osiguranjem radničkih tražbina podrazumijeva se posebna zaštita materijalnih prava radnika čiji poslodavac postane insolventan i ne isplaćuje plaće radnicima. Isplata radničkih tražbina radila se u okviru bivšeg Fonda

za razvoj i zapošljavanje, a od 2008. godine sukladno Direktivi 2008/94/EZ Europskoga parlamenta o zaštiti zaposlenika u slučaju insolventnosti njihovog poslodavca (SL L 283, 28. 10. 2008.), osnovana je Agencija za osiguranje radničkih tražbina (dalje u tekstu: AORT). Direktiva je propisala da države članice trebaju osnovati tijelo koje jamči isplatu nepodmirenih potraživanja zaposlenika (preambula i članak 3.) (Europski parlament, 2008). Djelokrug ovlasti i rad AORT-a bili su određeni Zakonom o osiguranju potraživanja radnika u slučaju stečaja poslodavca (Narodne novine, br. 86/08) koji je kasnije tijekom godina mijenjan da bi konačno 2017. godine bio donesen potpuno novi Zakon o osiguranju radničkih tražbina (Narodne novine, br. 70/17) (dalje u tekstu: Zakon) kojim su utvrđena pravna pravila o zaštiti materijalnih prava iz radnog odnosa u slučaju otvaranja stečajnog postupka nad poslodavcem i u slučaju blokade računa poslodavca zbog nemogućnosti prisilne naplate neisplaćene plaće.

3.2. Prava radnika u slučaju blokade računa poslodavca

Institut blokade računa poslodavca podrazumijeva situaciju kada je poslodavac zbog neisplate plaće do konca tekućeg mjeseca za prethodni mjesec, sukladno Zakonu, obvezan u FINA-i blokirati svoj poslovni račun u korist plaće radnika. Ovaj postupak naplate plaće putem prisilne blokade računa u zakonodavstvo je uveden potkraj 2015. godine kada je prema podacima Inspektorata rada¹ situacija u gospodarstvu bila da više od 6.293 poslodavca nisu na vrijeme isplaćivali plaću za 21.647 radnika, dok je primjenom Zakona prosječni mjesečni broj neisplata plaća sveden na 494 poslodavca i oko 1.595 radnika². Ako i nakon prisilne blokade svog računa u korist isplate plaće radniku poslodavac nije u mogućnosti isplatiti plaću, onda podnosi zahtjev AORT-u da umjesto njega isplati dio plaće radnicima.

Ako AORT ocijeni da je zahtjev u skladu sa Zakonom, radnik ostvaruje pravo na isplatu:

¹ Inspektorat rada je Zakonom o izmjenama i dopunama Zakona o ustrojstvu i djelokrugu ministarstava i drugih središnjih tijela državne uprave (Narodne novine, br. 116/18), od 1. travnja 2019. spojen s Državnim inspektoratom kao središnjim tijelom državne uprave.

² Državni inspektorat, Godišnje izvješće o radu Državnog inspektorata za 2019. godinu, <https://dirh.gov.hr/UserDocsImages/planovi/Godi%C5%A1nje%20izvje%C5%A1%C4%87e%20o%20radu%20DIRH%20za%202019.%20godinu.pdf> (učitano 10. kolovoza 2021.).

1) do tri neisplaćene plaće odnosno naknade plaće, u visini do iznosa minimalne plaće za svaki mjesec za koji plaća odnosno naknada plaće nije isplaćena i

2) do tri neisplaćene naknade plaće za bolovanje koju je prema propisima o zdravstvenom osiguranju bio dužan isplatiti poslodavac iz svojih sredstava, u visini do iznosa minimalne plaće za svaki mjesec proveden na bolovanju.

Sva primanja koja radnik ostvari na temelju ovih prava u cijelosti su izuzeta od ovrhe. AORT ima rok od 7 dana za donošenje rješenja po uredno zaprimljenom zahtjevu.

3.3. Prava radnika u slučaju otvaranja stečajnog postupka nad poslodavcem

Zakonom su u slučaju otvaranja stečajnog postupka nad poslodavcem osigurana prava radnika na isplatu:

- 1) neisplaćene plaće odnosno naknade plaće, u visini do iznosa minimalne plaće za svaki mjesec zaštićenog razdoblja
- 2) neisplaćene naknade plaće za bolovanje u zaštićenom razdoblju koju je prema propisima o zdravstvenom osiguranju bio dužan isplatiti poslodavac iz svojih sredstava, u visini do iznosa minimalne plaće za svaki mjesec proveden na bolovanju
- 3) neisplaćene naknade za neiskorišteni godišnji odmor na koji je radnik stekao pravo do otvaranja stečajnog postupka pod uvjetima utvrđenim zakonom, u visini do iznosa minimalne plaće, kao ekvivalenta mjesečnoj plaći iz točke 1. ovoga stavka
- 4) otpremnine pod uvjetima utvrđenim zakonom, u visini polovice otpremnine utvrđene u stečajnom postupku, a najviše do polovice najvišeg iznosa zakonom propisane otpremnine i
- 5) pravomoćno dosuđene naknade štete zbog pretrpljene ozljede na radu ili profesionalne bolesti, u visini do jedne trećine pravomoćno dosuđene naknade štete.

Potrebno je naglasiti da su sva primanja po gore navedenim isplatama u cijelosti izuzeta od ovrhe. Radnici do svojih primanja prema ovom Zakonu mogu doći kada je stečajni postupak nad poslodavcem otvoren i kada

trgovački sud rješenjem utvrdi pojedinačne tražbine radnika. Radnik se AORT-u obraća putem zahtjeva i AORT ima obvezu odlučiti rješenjem u roku od 15 dana od dana podnošenja urednog zahtjeva. Isplata na poseban račun stečajnog dužnika ili na račune radnika vrši se u roku od 15 dana od izvršnosti rješenja.

3.4. Struktura isplate osiguranih radničkih tražbina

U ovom dijelu rada prikazat će se isplate osiguranih radničkih tražbina za radnike čiji je poslodavac imao blokadu računa zbog neisplate plaća i za radnike čiji je poslodavac završio u stečaju. Ranije je rečeno da će podaci obuhvaćati razdoblje od 1. siječnja 2017. godine do 30. lipnja 2021. godine kako bi se mogli izvući određeni zaključci vezano za pandemiju koronakrize.

Tablica u nastavku nam daje prikaz isplata radnicima u slučaju blokade računa poslodavca zbog nemogućnosti isplate plaće. Podaci su prikazani kvartalno radi preglednosti. U četvrtom kvartalu 2018. godine bila je visoka isplata za grupu Uljanik d.d. Isplaćeno je ukupno 40.111.751 kuna za 3 877 radnika³. Ta isplata izuzeta je iz ove tablice jer ima veoma snažan statistički utjecaj na trendove i mogli bi se izvesti pogrešni zaključci.


³ AORT., Godišnje izvješće o radu Agencije za 2018. godinu, <https://www.aort.hr/naslovnica/dokumenti-agencije/godisnje-izvjesce-o-radu-agencije/2018-godina/> (učitano 10. kolovoza 2021.).

**Tablica 1. Isplata radničkih tražbina u slučaju blokade računa
poslodavca zbog nemogućnosti isplate plaće**

Godina isplate			
2017.	Ukupna isplata	Broj poslodavaca	Broj radnika
prvi kvartal	1.314.790	12	199
drugi kvartal	2.183.893	12	277
treći kvartal	6.129.441	17	626
četvrti kvartal	1.024.632	17	162
UKUPNO 2017.	10.652.756	58	1.264
2018.			
prvi kvartal	418.334	13	77
drugi kvartal	207.960	6	42
treći kvartal	5.231.644	13	549
četvrti kvartal	1.746.982	12	408
UKUPNO 2018.	7.604.920	44	1.076
2019.			
prvi kvartal	2.514.070	12	385
drugi kvartal	1.982.847	12	230
treći kvartal	806.998	6	119
četvrti kvartal	974.929	7	109
UKUPNO 2019.	6.278.844	37	843
2020.			
prvi kvartal	980.415	11	158
drugi kvartal	260.692	10	38
treći kvartal	1.107.330	3	96
četvrti kvartal	1.745.218	8	163
UKUPNO 2020.	4.093.655	32	455
2021.			
prvi kvartal	1.078.393	14	157
drugi kvartal	2.606.499	10	247
UKUPNO 2021.	3.684.892	24	404
SVEUKUPNO	32.315.067	195	4.042


Izvor: obrada podataka prema podacima AORT-a.

Grafikon 3. Grafički prikaz isplate radničkih tražbina u slučaju blokade računa poslodavca



Izvor: obrada podataka prema podacima AORT-a.

Grafikon 4. Isplata radničkih tražbina u slučaju blokade računa poslodavca (broj poslodavaca i broj radnika)



Izvor: obrada podataka prema podacima AORT-a.

Institut blokade računa poslodavca dolazi u situaciji kada poslodavac nije u mogućnosti isplatiti plaću radnicima. Sukladno Zakonu obavezan je blokirati svoj poslovni račun u FINA-i, a ako nema sredstava na računu, obavezan je u roku od tri dana podnijeti zahtjev AORT-u za isplatu plaće radnicima.

Iz podataka je vidljivo da je broj poslodavaca u prva dva kvartala 2017. godine bio 24, pa 2018. godine 19, zatim 2019. godine ponovno 24 te *pandemijske* 2020. i 2021. godine u prva dva kvartala 21 odnosno 24 poslodavaca su se obratili AORT-u za isplatu plaće radnicima. Primjetno je da je u trećem i četvrtom kvartalu 2020. godine bilo samo 11 poslodavaca koji su podnijeli zahtjev AORT-u za isplatu plaće radnicima. Dakle, unatoč koronakrizi i vezano za to problemima u gospodarstvu, nije došlo do povećanja priljeva zahtjeva poslodavaca prema AORT-u za isplatu plaće radnicima. Broj zahtjeva ostao je na prosjeku kao i prethodnih "normalnih" godina tržišnog poslovanja.

Kada je u pitanju stečaj poslodavca i isplate vezane na taj institut, također je kao i kod blokade računa poslodavca potrebno učiniti određenu intervenciju u podatke. U ovom slučaju osim grupe Uljanik d.d. u stečaju radi se i o isplatama bivšim radnicima grupe Viadukt d.d. u stečaju. U prvom i drugom kvartalu 2018. godine za bivše radnike grupe Viadukt d.d. u stečaju

isplaćeno je ukupno 20.679.958 kuna za 925 radnika, dok je u trećem i četvrtom kvartalu 2019. godine isplaćen 1.691 radnik grupe Uljanik d.d. u stečaju u ukupnom iznosu od 44.151.527 kuna. Ovi iznosi, kao i dodatno isplaćeni iznos u prvom kvartalu 2020. godine od 10.839.928 kuna za 519 bivših radnika grupe Uljanik d.d. u stečaju, nisu uzeti u analizu u ovom pregledu⁴. Razlog za isključenje tih isplata iz analize je taj što su iznosi ekstremno veliki, a za mali broj poduzetnika, tako da bi se usporedbom podataka došlo do pogrešnih zaključaka vezano za trend kretanja.


Tablica 2. Isplata radničkih tražbina u slučaju stečaja poslodavca

Godina isplate			
2017.	Ukupna isplata	Broj poslodavaca	Broj radnika
prvi kvartal	7.575.249	20	420
drugi kvartal	1.193.698	20	67
treći kvartal	7.594.711	23	416
četvrti kvartal	2.393.233	12	106
UKUPNO 2017.	18.756.891	75	1.009
2018.			
prvi kvartal	1.834.477	24	135
drugi kvartal	6.737.591	18	432
treći kvartal	1.673.008	23	105
četvrti kvartal	2.136.865	20	177
UKUPNO 2018.	12.381.941	85	849
2019.			
prvi kvartal	3.663.324	15	303
drugi kvartal	492.779	10	38
treći kvartal	8.028.095	23	455
četvrti kvartal	2.093.174	9	101
UKUPNO 2019.	14.277372	57	897
2020.			
prvi kvartal	3.113.269	16	103
drugi kvartal	1.851.114	13	124
treći kvartal	1.267.243	13	79
četvrti kvartal	5.383.475	16	465
UKUPNO 2020.	11.615.101	58	771
2021.			
prvi kvartal	1.244.691	12	130
drugi kvartal	757.958	11	60
UKUPNO 2021.	2.002.649	23	190
SVEUKUPNO	59.033.954	298	3.716

Izvor: obrada podataka prema podacima AORT-a.


⁴ AORT, godišnja izvješća o radu Agencije za 2018., 2019., i 2020. godinu, <https://www.aort.hr/naslovnica/dokumenti-agencije/> (učitano 10. kolovoza 2021.).

Grafikon 5. Grafički prikaz isplata radničkih tražbina u slučaju stečaja poslodavca



Izvor: obrada podataka prema podacima AORT-a.

Grafikon 6. Isplata radničkih tražbina u slučaju stečaja poslodavca (pregled po broju radnika i broju poslodavaca)



Izvor: obrada podataka prema podacima AORT-a.

Iz prikazanih podataka vidljivo je da početak koronakrize u proljeće 2020. godine nije utjecao na povećanje trenda isplata radničkih tražbina putem AORT-a za radnike čiji je poslodavac završio u stečaju. Naime, u prva dva kvartala 2017. godine AORT je izvršio isplatu radnicima 40 poslodavaca, u 2018. godini za prva dva kvartala isplata je bila za 42 poslodavca, 2019. godine za 25 poslodavaca u pandemijskoj 2020. godini za prva dva kvartala isplata je bila za 29 poslodavaca, dok je 2021. godine u prva dva kvartala izvršena isplata za radnike kod 23 poslodavca. Kod analize podataka vezano za stečaj, treba imati na umu činjenicu da od otvaranja stečajnog postupka pa do održavanja prvog ročišta i utvrđivanja tražbina na trgovačkim sudovima u prosjeku prođu tri mjeseca. Zbog toga je, vezano za utjecaj koronakrize na poslovanje poduzetnika, za vjerodostojniju analizu bolje uzeti podatke trećeg i četvrtog kvartala. Kad se gledaju ti kvartali, podaci pokazuju da je za treći i četvrti kvartal 2017. godine AORT vršio isplatu za 35 poslodavaca, u 2018. za 43 poslodavca, u 2019. za 32 poslodavca te u trećem i četvrtom kvartalu 2020. za 29 poslodavaca.

U životnom ciklusu poduzeća kada nastupe problemi u poslovanju, najčešće prvo ide blokada poslovnog računa a ako su problemi u poslovanju nepremostivi, otvara se i stečajni postupak. Ranije je rečeno da je institut isplate radničkih tražbina u slučaju blokade računa poslodavca u zakonodavstvo RH uveden potkraj 2015. godine. Prema podacima AORT-a⁵ od početka primjene instituta blokade računa poslodavca ukupno je isplaćeno 91.334.870 kuna za 10.474 radnika zaposlenih kod 304 poslodavca. Od tog broja poslodavaca u likvidaciji ili stečaju završila su 203 poslodavca odnosno nešto više od 66% poslodavaca. Iz ovog podatka izvlači se zaključak da u vrijeme koronakrize broj poduzetnika zapalih u krizu nije odstupao od prosjeka broja poduzetnika koji inače zapadnu u krizu, a uz odgovarajuću primjenu novih Vladinih mjera pomoći gospodarstvu, to neće utjecati ni na porast stečajnih postupaka uvjetovanih koronakrizom.

Podatak koji je na tragu prethodne tvrdnje je i taj da je prema podacima Ministarstva pravosuđa i uprave u prvom polugodištu 2019. godine na trgovačkim sudovima primljeno 806 zahtjeva za pokretanje stečajnog postupka nad društvima s ograničenom odgovornošću, u prvom polugodištu 2020. godine primljeno je 730 zahtjeva, dok je u prvom polugodištu 2021.

⁵ AORT, podaci o isplatama, <https://www.aort.hr/naslovnica/informacije-o-isplati/> (učitano 10. kolovoza 2021.).

godine primljeno 460 zahtjeva za otvaranje stečajnog postupka nad d.o.o. Dakle, u vrijeme koronakrize nije došlo do porasta zahtjeva za otvaranjem stečajnih postupaka nad d.o.o. U promatranom razdoblju došlo je do porasta *skraćenih stečajnih* postupaka. U prvom polugodištu 2019. godine bilo je 1.617 postupaka, 2020. godine 1.020, dok je u prvom polugodištu 2021. godine pokrenuto 2.445 skraćenih stečajnih postupaka. Kod skraćenih stečajnih postupaka uglavnom se radi o postupcima koje nakon 120 dana neprekidne blokade pokreće FINA. Prema podacima s portala *Poslovna Hrvatska* više od 85% poduzeća nad kojima je pokrenut skraćeni stečajni postupak nemaju nijednog ili imaju samo jednog zaposlenog radnika⁶. Iz toga proizlazi da se nije značajno povećao broj nezaposlenih radnika zbog porasta broja skraćenih stečajnih postupaka. Također na porast broja skraćenih stečajnih postupaka utjecalo je što je na dan 19. listopada 2020. godine prestala primjena mjere Vlade RH kojom je bilo naloženo FINA-i da zastane s provedbom ovrhe na novčanim sredstvima u odnosu na ovršenike fizičke osobe za vrijeme trajanja *posebnih okolnosti*. *Posebne okolnosti* sukladno izmjenama Zakona o provedbi ovrhe na novčanim sredstvima (Narodne novine, br. 47/20), znače događaj ili određeno stanje koje se nije moglo predvidjeti i na koje se nije moglo utjecati, a koje ugrožava život i zdravlje građana, imovinu veće vrijednosti, znatno narušava okoliš, narušava gospodarsku aktivnost ili uzrokuje znatnu gospodarsku štetu. Pandemija COVID-19 definitivno je takva jedna posebna okolnost. Na dan 18. travnja 2020. godine kad su na snagu stupile izmjene Zakona o provedbi ovrhe na novčanim sredstvima, FINA je:

- zastala s provedbom ovrhe na novčanim sredstvima za ukupno 244.865 ovršenika fizičkih osoba (uključeni su i potrošači/građani, njih 234.587 i fizičke osobe koje obavljaju registriranu djelatnost, njih 10.269);
- zastala s provedbom 1.089.620 osnova za plaćanje;
- ukupan iznos nenaplaćenog duga ovršenika fizičkih osoba za koji se zastalo u provedbi ovrhe bio je 17,2 mlrd. kuna glavnice i 6,7 mlrd. kuna kamata (FINA, 2020).

⁶ Podatak obrađen prema podacima portala *Poslovna Hrvatska*, *Poslovna Hrvatska – Naslovna*, (učitano 12. kolovoza 2021.).

4. ZAKLJUČAK

Na početku pandemije COVID-19 u proljeće 2020. godine došlo je do situacije kada je gospodarstvo diljem svijeta stalo, prekinuti su lanci opskrbe i došlo je do pada potražnje. U roku kraćem od tri mjeseca nakon izbijanja krize COVID-19, ekonomisti su postigli konsenzus da je svijet zahvatila globalna recesija (Giles, Greeley i Arnold, 2020). Ova recesija imala je drugačiji izvor od globalne krize 2008. – 2009. godine koja je nastala iz financijske krize i proširila se globalno. I tada su države različitim mjerama reagirale kako bi se kriza što prije okončala. Vlada RH u to vrijeme nije dala pravi odgovor na krizu, tako da je RH od svih zemalja Nove Europe pretkrizni BDP dosegla tek početkom 2019. godine (Globan, 2019).

Na ovu koronakrizu prema iznesenim pokazateljima Vlada RH je na vrijeme reagirala kako bi stabilizirala gospodarstvo i kako se ne bi ugrozilo funkcioniranje zdravstvenog sustava. Mjere za pomoć gospodarstvu koje je Vlada RH usvojila 17. ožujka 2020. godine na svojoj 214. sjednici (66 mjera) i odmah zatim i drugi paket mjera koji je usvojen 2. travnja 2020. godine na 222. sjednici Vlade RH, utjecali su na brzo postizanje gospodarske stabilnosti u najtežim danima pojave epidemije koronavirusa (Vlada RH, 2020).

U ovom radu posebno se analizirala mjera Potpora za očuvanje radnih mjesta u djelatnostima pogođenima koronavirusom i njezin neposredan utjecaj na broj podnošenja zahtjeva AORT-u za isplatu osiguranih radničkih tražbina.

U drugom poglavlju izneseni su podaci Hrvatskog zavoda za zapošljavanje gdje je na ime Potpore od primjene mjere od ožujka 2020. godine do lipnja 2021. godine isplaćeno ukupno 11,053 milijarde kuna za u prosjeku mjesečno 200 tisuća radnika kod 50 tisuća poduzetnika. Mjera se pokazala kratkoročno i srednjoročno, u kombinaciji s drugim mjerama podržavanja likvidnosti gospodarskih subjekata, jako učinkovitom. Naime, podaci iz trećeg poglavlja ovog rada pokazuju da nije došlo do porasta broja zahtjeva prema AORT-u za isplatu osiguranih radničkih tražbina. Broj zahtjeva je bio na razini *dobrih* gospodarskih godina, pa čak i nešto niži. Da mjere nisu bile dobro pogođene, poslodavci bi završili u blokadi računa ili stečaju i došlo bi do *tsunamija* zahtjeva njihovih radnika prema AORT-u. No taj se scenarij izbjegao.

Iz *Analize fiskalnih i ekonomskih učinaka potpore za očuvanje radnih mjesta u djelatnostima pogođenima koronavirusom*, koje su za HZZ izradili Primorac i suradnici (Primorac, Šimović, i Arčabić, 2020) proizlazi da su isplaćene Potpore bile i financijski povoljnije za državu od isplata naknada za nezaposlene osobe. Predmetna *analiza* pokazala je i da je mjera Potpora bila dobro ciljana na ugrožene djelatnosti.

U analizi posljedica nezaposlenosti, nezaposlene osobe ne smiju se samo hladno statistički promatrati kao broj. Ostanak radnika bez posla osim ekonomskih ima i određene socijalne posljedice. *Ekonomske posljedice* odnose se na pojedinca i na gospodarstvo. Vezano za pojedinca, ekonomske posljedice bile bi smanjenje kućnog budžeta, povećana zaduženost, povećano izdvajanje za zdravstvene usluge i sl. Gospodarstvo, odnosno država ima veća izdvajanja za nezaposlenost, manji je priljev poreznih prihoda, niža stopa rasta BDP-a i sl. *Socijalne posljedice* za pojedinca bile bi povećana razina stresa, psihološki problemi i drugo, čija analiza nadilazi opseg i temu ovog rada. Jedna od posljedica duže nezaposlenosti je slabljenje radnih vještina i sl., čime dolazi do pada produktivnosti, što izravno utječe i na gospodarstvo. Raspodjela BDP-a postaje neravnomjernija i gospodarstvo radi ispod punog potencijala. Čovjek bez rada ne može korisno upotrijebiti svoju energiju i znanje i biti pokretač i nositelj razvoja i napretka. Nezaposlenost utječe na samu srž ljudskog bića i smisla njegova osnovnog prava – prava na rad. Nezaposleni radnici koji su dulje vrijeme izloženi nezaposlenosti suočavaju se s gubitkom svojih radnih vještina te smanjenjem mogućnosti pronalaska novog posla. U svojoj enciklici *Laborem exercens – Radom čovjek*, papa Ivan Pavao II., govoreći o problemu rada i zaposlenja, kaže "*Zadaća je svih da djeluju protiv nezaposlenosti, koja je uvijek zlo, a kad dosegne određene dimenzije, postaje prava društvena nevolja. Naročito je bolan problem kad nezaposlenost pogađa prvenstveno mlade koji, ..., ne uspijevaju naći zaposlenje, i s ogorčenjem gledaju kako se izjalovljuje njihova iskrena volja da rade i njihova raspoloženost da preuzmu svoju odgovornost za ekonomski i društveni razvitak zajednice*" (Wojtyła, 2003).

Imajući na umu posljedice koje izaziva nezaposlenost, jasno je zašto je najizdašnija mjera Vlade RH bila Potpora za očuvanje radnih mjesta. Do kada će ta mjera trajati nije izvjesno, jer nije izvjesno ni kada će prestati pandemija koronavirusa. Očekivanja su da će se gospodarstvo potpuno oporaviti od ove krize dosta brzo jer ne postoje akumulirane makroekonomske neravnoteže, a i poduzeća su tijekom krize dodatno

ulagala u digitalizaciju poslovanja, što će zasigurno utjecati i na povećanje produktivnosti.

Istraživanja su pokazala da reakcija tržišta rada na ekonomske šokove nije samo trenutna nego se posljedice šoka osjete i kroz sljedeće tri godine (Globan, 2019; Škare, 2014; Jandrić, 2014; Möller, 2010; Monte i Pinheiro, 2021) te da utjecaj šoka i njegova dužina ovisi i o sektorskim politikama i postizanju ravnoteže gospodarstva (Kikuchi, Kitao i Mikoshiba, 2021) te rigidnosti na tržištu rada (Dumančić, 2019; Dix-Carneiro i Pessoa, 2021). Dosadašnja politika Vlade RH u suzbijanju negativnih posljedica koronakrize na zaposlenost dovela je do toga da su na burzi rada potkraj 2021. godine bile registrirane 126.232 nezaposlene osobe, a broj zaposlenih bio je veći za 22,8 tisuća (+1,5 posto) u odnosu na svibanj, te je potkraj lipnja 2021. broj zaposlenih iznosio 1,596 milijuna (MacroHub, 2021), a na dan 31. srpnja 2021. godine ukupno zaposlenih bilo je 1,606 milijuna, što je u usporedbi s istim razdobljem pretpandemijske 2019. godine više za 6 128 zaposlenih (Hrvatski zavod za mirovinsko osiguranje, 2021).

Paket mjera koji se primjenjuje u koronakrizi potrebno je nadograditi strukturnim mjerama koje će osigurati zapošljivost i veću mobilnost radne snage u svim sektorima gospodarstva. Kratkoročna mjera očuvanja radnih mjesta polučila je svoj osnovni cilj, osiguranje socijalnog minimuma i zadržavanje radnih mjesta. Mjera može, ovisno o situaciji, biti više ili manje zastupljena, ali na donosiocima gospodarskih politika je provođenje sveobuhvatnih usvojenih strukturnih promjena. Vlada RH je donijela, a Europska komisija potvrdila Nacionalni plan oporavka i otpornosti 2021. – 2026. ukupne procijenjene vrijednosti 47,5 milijardi kuna (Vlada RH, 2021). Provedba Plana bit će ogroman poticaj provođenju strukturnih promjena i poticanju rasta i otpornosti hrvatskoga gospodarstva i "stvaranje preduvjeta za otvaranje najmanje 100.000 novih radnih mjesta" (Vlada RH, 2021, str. 914). Republika Hrvatska do 2030. godine, kako je u Nacionalnoj razvojnoj strategiji 2030. (Vlada RH, 2021) vidi Vlada RH, je konkurentna, inovativna i sigurna zemlja prepoznatljivog identiteta i kulture, zemlja očuvanih resursa, kvalitetnih životnih uvjeta i jednakih prilika za sve.

LITERATURA

Adams-Prassl, A., & al, e. (23. travnja 2020.). *Inequality in the Impact of the Coronavirus Shock: Evidence from Real Time Surveys*. Dohvaćeno iz Inet Econ Cam: <https://www.inet.econ.cam.ac.uk/working-paper-pdfs/wp2018.pdf>

Andreosso-O'Callaghan, B., Moon, W., & Sohn, W. (29. rujna 2021.). *Economic Policy and the Covid-19 Crisis: The Macroeconomic Response in the US, Europe and East Asia*. Dohvaćeno iz Taylor i Francis Group: <https://doi.org/10.4324/9781003153603>

Dix-Carneiro, R., & Pessoa, P. J. (siječanj 2021.). *Globalization, Trade Imbalances and Labor Market Adjustmen*. Dohvaćeno iz National Bureau of Economic Research: <https://www.nber.org/papers/w28315>

Dumančić, L. R. (2019). *Utjecaj strukturnih politika na izvoznu konkurentnost Republike Hrvatske*. Zagreb: Ekonomski fakultet – Zagreb.

Europska komisija. (svibanj 2020.). *Proljetna gospodarska prognoza 2020*. Dohvaćeno iz Europska komisija: https://ec.europa.eu/info/sites/default/files/economy-finance/ip125_en.pdf

Europska komisija. (12. svibnja 2021.). *Spring 2021 Economic Forecast: Rolling Up Sleeves*. Dohvaćeno iz Europska komisija: https://ec.europa.eu/info/business-economy-euro/economic-performance-and-forecasts/economic-forecasts/spring-2021-economic-forecast-rolling-sleeves_en#documents

Europski parlament. (22. listopada 2008.). *Direktiva 2008/94/EZ*. Dohvaćeno iz Europski parlament: <https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:32008L0094&from=EN>

Fabrizio, S., Diego, G. B., & Tavares, M. M. (18. ožujka 2021.). *The COVID-19 She-Cession: The Employment Penalty of Taking Care of Young Children*. *Centre for Economic Policy Research*, str. 136-162.

FINA. (20. travnja 2020.). *Financijska agencija*. Dohvaćeno iz FINA: <https://www.fina.hr/-/zastoj-ovrhe-na-novcanim-sredstvima-mjera-pomoci-fizickim-osobama-uslijed-pojave-epidemije-bolesti-covid-19>

Giles, C., Greeley, B., & Arnold, M. (24. travnja 2020.). *Global Recession Already Here, Say Top Economists*. Dohvaćeno iz Financial Times: <https://www.ft.com/content/be732afe-6526-11ea-a6cd-df28cc3c6a68>

Globan, T. (13. lipnja 2019.). *Zadnja od svih zemalja Nove Europe, Hrvatska je dosegla pretkriznu razinu BDP-a*. Dohvaćeno iz Macrohub: <https://macrohub.net.efzg.hr/analize/13-06-2019-hrvatska-je-dostigla-pretkriznu-razinu-bdp-a>

Hershbein, B. J., & Holzer, H. J. (18. ožujka 2021.). The COVID-19 Pandemic's Evolving Impacts on the Labour Market: Who's Been Hurt and What We Should Do. *Centre for Economic Policy Research*, str. 68-121.

Hrvatski zavod za mirovinsko osiguranje. (6. kolovoza 2021.). *Hrvatski zavod za mirovinsko osiguranje i u srpnju 2021. bilježi kontinuirani porast broja osiguranika*. Dohvaćeno iz Mirovinsko.hr: <https://www.mirovinsko.hr/hr/hrvatski-zavod-za-mirovinsko-osiguranje-i-u-srpnju-2021-biljezi-kontinuirani-porast-broja-osiguranika/1878>

HZZ. (28. svibnja 2020.). 2. *sjednica Upravnog vijeća*. Dohvaćeno iz Hrvatski zavod za zapošljavanje: https://www.hzz.hr/content/sjednice-uv/02-2020/Potpورا-za-ocuvanje-radnih-mjesta-za-lipanj-2020_.doc

HZZ. (20. ožujka 2020.). 55. *sjednica Upravnog vijeća*. Dohvaćeno iz Hrvatski zavod za zapošljavanje: <https://www.hzz.hr/o-hzz/upravno-vijece/55-sjednica-upravnog-vijeca-hzz.php>

HZZ. (25. ožujka 2020.). 56. *sjednica Upravnog vijeća*. Dohvaćeno iz Hrvatski zavod za zapošljavanje: https://www.hzz.hr/content/sjednice-uv/56-2020/UV_izmjena%20kriterija%20-%20ozujak%202020.%20-%20UV%20II.doc

HZZ. (7. travnja 2020.). 57. *sjednica Upravnog vijeća*. Dohvaćeno iz Hrvatski zavod za zapošljavanje: https://www.hzz.hr/content/sjednice-uv/57-2020/UV_izmjena%20kriterija%20-%20travanj%202020.%2006%2004..DOC

HZZ. (29. srpnja 2020.). 7. *sjednica Upravnog vijeća*. Dohvaćeno iz Hrvatski zavod za zapošljavanje: <https://www.hzz.hr/content/sjednice-uv/07-2020/Potpورا-za-ocuvanje-radnih-mjesta-OSI.doc>

HZZ. (7. rujna 2020.). 9. *sjednica Upravnog vijeća*. Dohvaćeno iz Hrvatski zavod za zapošljavanje: https://www.hzz.hr/content/sjednice-uv/09-2020/HZZ_Potpورا-za-ocuvanje-radnih-mjesta-rujan_prosinac-2020_07092020.doc

HZZ. (4. prosinca 2020.). *13. sjednica Upravnog vijeća*. Dohvaćeno iz Hrvatski zavod za zapošljavanje: https://www.hzz.hr/content/sjednice-uv/13-2020/UV_izmjena-kriterija-studeni-2020-0412.doc

HZZ. (8. siječnja 2021.). *15. sjednica Upravnog vijeća*. Dohvaćeno iz Hrvatski zavod za zapošljavanje: https://www.hzz.hr/content/sjednice-uv/15-2021/UV_izmjena-kriterija-sijecanj-2021.08.01..doc

HZZ. (3. ožujka 2021.). *19. sjednica Upravnog vijeća*. Dohvaćeno iz Hrvatski zavod za zapošljavanje: https://www.hzz.hr/content/sjednice-uv/19-2021/Izmjena_uvjeti_nacini_koristenja_potpore_050321-FINAL.doc

Jandrić, M. (listopad 2014.). Reakcije različitih institucionalnih modela tržišta rada u recesiji. *Ekonomski vidici*, str. 117-127.

Kikuchi, S., Kitao, S., & Mikoshiba, M. (ožujak 2021.). *Who Suffers from the COVID-19 Shocks? Labor Market Heterogeneity and Welfare Consequences in Japan*. Dohvaćeno iz Science Direct: <https://doi.org/10.1016/j.jjie.2020.101117>

MacroHub. (28. srpnja 2021.). *Semafori tržišta rada*. Dohvaćeno iz Macro Hub: <https://macrohub.net.efzg.hr/indikatori/tr%C5%BEi%C5%A1te-rada>

Möller, J. (22. siječnja 2010.). The German Labor Market Response in the World Recession – Demystifying a Miracle. *Journal for Labour Market Research*, str. 325-336.

Monte, D., & Pinheiro, R. (26. svibnja 2021.). *Labor Market Competition over the Business Cycle*. Dohvaćeno iz Wileya Online Library: <https://onlinelibrary.wiley.com/doi/abs/10.1111/ecin.13000>

Narodne novine, br. 47/20. *Zakon o dopuni Zakona o provedbi ovrhe na novčanim sredstvima*. Dohvaćeno iz Narodne novine: https://narodne-novine.nn.hr/clanci/sluzbeni/2020_04_47_952.html

Narodne novine, br. 70/17. *Zakon o osiguranju radničkih tražbina*. Dohvaćeno iz Narodne novine: https://narodne-novine.nn.hr/clanci/sluzbeni/2017_07_70_1658.html

Narodne novine, br. 86/08. *Zakon o osiguranju potraživanja radnika u slučaju stečaja poslodavca*. Dohvaćeno iz Narodne novine: https://narodne-novine.nn.hr/clanci/sluzbeni/2008_07_86_2753.html

Narodne novine, br. 17/08. *Zakon o osiguranju potraživanja radnika u slučaju stečaja poslodavca*. Dohvaćeno iz Narodne novine: https://narodne-novine.nn.hr/clanci/sluzbeni/2008_07_86_2753.html

Narodne novine, br. 93/14, 127/17 i 98/19. Dohvaćeno iz Narodne novine: <https://www.zakon.hr/z/307/Zakon-o-radu>

Europski parlament. (22. listopada 2008.). *Direktiva 2008/94/EZ*. Dohvaćeno iz Europski parlament: <https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:32008L0094&from=EN>

Primorac, M., Šimović, H., i Arčabić, V. (2020). *Analiza fiskalnih i ekonomskih učinaka potpore za očuvanje radnih mjesta u djelatnostima pogođenima koronavirusom (COVID-19)*. Zagreb: Hrvatski zavod za zapošljavanje.

Škare, M. (2014). Mjerenje međuzavisnosti poslovnih ciklusa i ekonomskoga rasta u Hrvatskoj primjenom spektralne analize. *Razvojni potencijali hrvatskog gospodarstva* (str. 53-76). Zagreb: Ekonomski fakultet Zagreb. Dohvaćeno iz Ekonomski fakultet Zagreb.

Vlada Republike Hrvatske. (17. ožujka 2020.). *Vlada na sjednici donijela mjere za pomoć gospodarstvu*. Dohvaćeno iz Vlada Republike Hrvatske: <https://vlada.gov.hr/sjednice/214-sjednica-vlade-republike-hrvatske-29015/29015>

Vlada Republike Hrvatske. (5. veljače 2021.). *Nacionalna razvojna strategija RH do 2030. godine*. Dohvaćeno iz Vlada RH: <https://hrvatska2030.hr/>

Vlada Republike Hrvatske. (8. lipnja 2021.). *Nacionalni plan oporavka i otpornosti 2021. – 2026*. Dohvaćeno iz Vlada Republike Hrvatske: <https://planoporavka.gov.hr/UserDocsImages/dokumenti/Plan%20oporavka%20i%20otpornosti%2C%20srpanj%202021..pdf?vel=13435491>

Wojtyła, K. J. (2003). *Laborem exercens – Radom čovjek*. Zagreb: Kršćanska sadašnjost.

THE INFLUENCE OF THE "JOB RETENTION" MEASURE ON THE PAYOUT OF WORKERS' CLAIMS IN THE CASE OF BANKRUPTCY OR A BLOCKED EMPLOYER'S ACCOUNT

Abstract

What this pandemic had in common was the uncertainty of its impact on economic trends. Never in history has the world economy stopped in its tracks as in the days of the COVID-19 pandemic.

The uncertainty of the impact stemmed from at least two reasons. The first reason was the impossibility of estimating the time necessary for finding an appropriate vaccine and the second was followed by the first, which was, depending on the duration, the uncertainty of the scope of the pandemic's impact on the individual components of the economy.

One of the biggest negative short-term impacts was expected in the area of increasing the number of unemployed persons due to lack of economic liquidity, blocking of corporate accounts and opening of bankruptcy proceedings against companies. Such an unfavorable scenario would put enormous pressure on public finances, which would be reflected in a reduction in state revenues and an increase in allocations for workers' rights pursuant to the Labor Market Act (Official Gazette 118/18 and 30/20) and the Workers' Claims Insurance Act (Official Gazette 70/2017).

The aim of the paper is to show how the Government's job retention measures have affected the payout of workers' claims in the case of bankruptcy or blocking of the employer's account. The paper will analytically, for a longer period of time, show the payments of workers' claims, the number of blocked employers and the number of employers against whom bankruptcy proceedings were initiated during the COVID-19 pandemic. It will be determined to what extent job retention measures had an impact on the payout of workers' claims through the Agency for the Protection of Workers' Claims. Likewise, the inflow of workers' requests for exercising rights in case of bankruptcy or blocking of the employer's account will be assessed.

For the purpose of gathering information, the websites of public law bodies of the Republic of Croatia, the Croatian Employment Service, the Agency for the Protection of Workers' Claims, the Financial Agency, the State

Inspectorate, and others were consulted. For the purposes of scientific research, and the design and presentation of research results in this paper, the following methods will be used in appropriate combinations: the method of description and comparison, methods of analysis and synthesis, the comparative method, the inductive and deductive method and evaluation methods.

Keywords: *worker's claim, job retention, COVID-19 pandemic.*

JEL klasifikacija: G30
Pregledni rad

UTJECAJ POTPORE NOVOOSNOVANIM PODUZEĆIMA ZA INOVACIJE I RAZVOJ NOVIH PROIZVODA I USLUGA PUTEM FONDOVA EUROPSKE UNIJE U REPUBLICI HRVATSKOJ

Ante Rončević*

Matija Kikelj**

SAŽETAK

Jedan od značajnih izazova novoosnovanih poduzeća je prikupljanje financijskih sredstava za realizaciju i komercijalizaciju poduzetničke ideje i ulaganje u inovacije. Još od 2009. godine, kada je financijska kriza utjecala na financijsku stabilnost poduzeća te obeshrabrila ulaganja u razvojne i inovativne pothvate, potpore postaju ključna ulaganja. Bespovratna sredstva iz fondova EU, ponajprije Europskog fonda za regionalni razvoj kroz mjere Operativnog programa Konkurentnost i kohezija 2014. – 2020., omogućuju ciljana ulaganja novoosnovanih poduzeća. Upravo navedene mjere operativnog programa Konkurentnost i kohezija djeluju u smjeru rasta i razvoja konkurentnosti novoosnovanih poduzeća kroz potporu za inovacije i komercijalizaciju inovativnih proizvoda i usluga.

U radu je provedena analiza najvažnijih financijskih pokazatelja poslovnih slučajeva četiri novoosnovana subjekta u Republici Hrvatskoj koji su iskoristili bespovratne potpore u okviru Poziva na dostavu projektnih prijedloga "Inovacije novoosnovanih MSP". Na navedenim primjerima

* Izv. prof. dr. sc. Ante Rončević, Sveučilište Sjever, Koprivnica – Varaždin (e-mail: aroncevic@unin.hr).

** Matija Kikelj, mag. iur., Sveučilište Sjever, Varaždin (e-mail: makikelj@unin.hr).

vidljiva je povezanost bespovratnih potpora na rast novoosnovanih poduzeća koja su ključna s obzirom na to da se najviše bore s nedostatkom sredstava za ulaganje u razvoj. Prikazani indikatori prikazuju učinkovitost potpora za ulaganje u inovacije i komercijalizaciju proizvoda u odnosu na rast i razvoj novoosnovanih poduzeća. Prikazani rezultati orijentir su za usmjerenje ulaganja iz fondova EU novog financijskog razdoblja te mogući smjer oporavka razvoja malih poduzetnika u području inovacija u postcovid razdoblju.

Ključne riječi: fondovi EU, potpore, inovacije, novoosnovana poduzeća.

1. UVOD

Suvremeno poduzetništvo nužno je promatrati kao proces koji naglašava sposobnost i aktivnost da, koristeći se promjenama, inovativnošću i prosudbom, a sve u uvjetima novih kombinacija ograničenih proizvodnih faktora, kreira i izvede pothvat koji će rezultirati profitom i ostalim društvenim koristima (Kružić, 2007).

Rizik suvremenog poduzetništva dodatno je naglasila potreba za konstantnim inovacijama zasnovanima na novim tehnologijama i njihova ugradnja u proizvode i usluge radi održavanja konkurentnosti, a tehnologija sama po sebi zahtijeva inovacije (Drucker, 1992).

Inovativnost predstavlja glavnu konkurentsku prednost, a financiranje inovativnosti predstavlja problem za poduzetnički sektor pogotovo u samim počecima realiziranja poslovnih ideja i planova. Velika poduzeća imaju uhodane odjele za istraživanje i razvoj, dok će u malima i novoosnovanim poduzećima inovativni proces biti gotovo u potpunosti neformalan. No manja poduzeća uobičajeno imaju prednost jer su agilna i brzo donose odluke, no limitirana su u pristupu kapitalu koji je neophodan za njihov razvoj (Prester, 2010).

Potpore imaju za cilj potaknuti rast i razvoj novoosnovanih poduzeća kroz ulaganje u inovacije i razvoj te uspješan prijenos inovativnih ideja u tržišno uspješno pothvate. Samo ulaganje u navedene aktivnosti je visokorizično, a uz teškoće u izvorima financiranja, ako su promašene, to je značajno izgubljen resurs i potrošeno vrijeme.

Predmet rada jest pregled okvira podrške za početna ulaganja novoosnovanih poduzeća u području inovacija i korištenje bespovratnih

potpora usmjerenih na uspješno lansiranje proizvoda i usluga s potencijalom rasta i izvoza koji su novi na tržištu. Uvodno je dan pregled okvira koji podržava razvoj novoosnovanih poduzeća za početna ulaganja (institucionalni i sadržajne mogućnosti izvora financiranja), kao dio okvira kojemu pripadaju i potpore za inovacije koje se dalje razrađuju kroz konkretan poziv u okviru Operativnog programa konkurentnost i kohezija.

U radu je provedeno kvalitativno istraživanje u kojem je dan pregled bespovratnih potpora koje su novoosnovana poduzeća mogla iskoristiti u svrhu inovacija i kreiranja novih proizvoda u financijskom razdoblju 2014. – 2020. Provedeno je i kvantitativno istraživanje koje kroz prikaz četiri poslovna slučaja različitih novoosnovanih poduzeća pomoću financijskih pokazatelja prikazuje povezanost bespovratnih sredstava i njihova poslovanja te prati povezanost dodijeljenih potpora za inovacije kroz razvojne rezultate, inovacijske procese, širenje poslovanja na novim tržištima i jačanje ljudskih kapaciteta.

Za potrebe ovog rada postavljena su istraživačka pitanja.

1. Utječu li potpore iz programa Konkurentnost i kohezija u razdoblju 2014. – 2020., usmjerene na inovacije, pozitivno na financijski rast poduzeća i komercijalizaciju razvijenih proizvoda?
2. Jesu li potpore novoosnovanim poduzećima pri pokretanju inovativnih ulaganja učinkoviti izvor financijskih sredstava?

2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA U PODRUČJU UTJECAJA POTPORA DODIJELJENIH PUTEM POZIVA FONDOVA EU ZA INOVACIJE I RAZVOJ PODUZEĆA

Istraživanja koja na primjeru proučavaju potpore iz programa Kohezija i razvoj u razdoblju 2014. – 2020. nema, kao ni onih koja daju pregled novoosnovanih poduzeća u Republici Hrvatskoj, a koja su iskoristila bespovratna sredstva iz navedenog programa.

Još 2005. godine Prohaska i Olegić Draženović istaknuli su problem financiranja malih i srednjih poduzeća u Republici Hrvatskoj. U svom radu analizirali su institucionalna i regulatorna ograničenja razvoja malog i srednjeg poduzeća (Prohaska i Olegić, 2005).

Marinac, Devčić i Raguž u radu "Regionalni razvoj Hrvatske u sklopu kohezijske politike Europske unije u financijskoj perspektivi 2014. – 2020." proučavaju utjecaj navedene politike na Republiku Hrvatsku (Marinac, Devčić, Raguž, 2014).

Đulabić je u svom radu Kohezijska politika Europske unije kao instrument razvoja Hrvatske dao pregled tada nove kohezijske politike za razdoblje 2014. – 2020. kao važnog instrumenta za ostvarivanje strateških ciljeva EU (Đulabić, 2014).

Od novijih istraživanja, Stanko Trček je u svom radu dao pregled smjernica za vrednovanje europske kohezijske politike te ističe kako se navedena politika vrednovala u svim fazama djelovanja. Navedeno praćenje propisuje Europska komisija u pravnim osnovama te je ona izdala i smjernice s detaljima o konceptu i metodologiji za praćenje i vrednovanje (Trček, 2016).

3. NOVOOSNOVANA PODUZEĆA I INOVACIJE

U ukupnom broju poduzeća u RH najveći udio ima sektor malih i srednjih poduzeća koja čine 99,7% ukupnog broja poduzeća. Poduzetnička aktivnost u Hrvatskoj mjerena TEA indeksom u 2018. iznosila je 9,6% (Centar za politiku razvoja malih i srednjih poduzeća i poduzetništva u suradnji s istraživačkim timom s Ekonomskog fakulteta u Osijeku, Sveučilište J. J. Strossmayera u Osijeku, u daljnjem tekstu: CEPOR, Izvješće o malim i srednjim poduzećima u Hrvatskoj – 2019).

Razlozi za pokretanje poduzetničkih pothvata vezuju se uz motivaciju za poduzetničko djelovanje, a rezultat su prepoznavanja poslovne prilike ili proizlaze iz nužnosti zbog primjerice nedostatka drugih opcija kod zaposlenja. TEA (*Total Early Entrepreneurial Activity*) indeks predstavlja broj poduzetnički aktivnih ljudi koji su ujedno i vlasnici poduzeća mlađih od 42 mjeseca u odnosu na 100 ispitanika između 18 i 64 godine starosti. GEM istraživanje (od 2002. godine provodi ga CEPOR) mjeri pokretanje poduzetničkih pothvata zbog prilike ili iz nužde indeksima TEA Prilika, TEA Nužnost i motivacijskim indeksom. Motivacijski indeks omjer je TEA Prilika prema TEA Nužnost. Veća vrijednost motivacijskog indeksa (vrijednost motivacijskog indeksa iznad 1) pokazuje da je više poduzetničkih pothvata pokrenuto zbog uočene prilike, dok je vrijednost ispod 1 pokazatelj pokretanja poduzetničkog pothvata iz nužnosti.

Motivacijski indeks Hrvatske u 2018. iznosio je 1,9, što znači da je 1,9 puta više poduzetnika ulazilo u poduzetničku aktivnost zbog uočene prilike, a ne iz nužde. No dugogodišnja visoka stopa nezaposlenosti u Hrvatskoj utjecala je i na visok udio poduzetnika koji se odlučuju na pokretanje poslovnog pothvata zbog nužde, koristeći mjere aktivne politike zapošljavanja iz paketa "od mjere do karijere" koje omogućuju financijsku podršku za novoosnovana poduzeća financiranu iz Europskog socijalnog fonda kroz Operativni program Učinkoviti ljudski potencijali (CEPOR, Izvješće o malim i srednjim poduzećima u Hrvatskoj – 2019).

Važnost i koristi od osnivanja i razvoja malog i srednjeg poduzeća su mnogostruke, konkurencija na tržištu raste i na takav način djeluje protiv monopolizacije, povećava se bogatstvo te dolazi do raznovrsnosti ponude koja izravno utječe na pravo izbora potrošača. Za istaknuti je kako je u 2020. godini, unutar sektora malog i srednjeg poduzetništva, osnovano ukupno 5.657 d.o.o., 5.850 j.d.o.o., 10.348 obrta (Ministarstvo gospodarstva i održivog razvoja: prikazani podaci o osnivanju trgovačkih društava (d.o.o. i j.d.o.o.) i obrta u Republici Hrvatskoj – prema podacima iz sudskog i obrtnog registra).

Prema Europskoj ljestvici uspjeha u inovacijama za 2018., Hrvatska je umjereno inovativna zemlja. Hrvatska je po GII za 2020. rangirana na 41. mjestu. Srednja i velika poduzeća u RH ulažu više od 90% svih privatnih investicija u istraživanje i razvoj, dok mikro i mala poduzeća ulažu manje od 8% (Operativni program konkurentnost i kohezija 2014. – 2020.).

Inovativna poduzeća definiraju se kao poduzeća koja su uvela inovaciju proizvoda ili inovaciju procesa (Vukičević, 2019). Inovativno je 45,8% malih poduzeća, 56,5% srednje velikih i 74,6% velikih poduzeća. Previsoki troškovi, manjak vlastitih sredstava za inovacije te drukčiji prioriteti unutar poduzeća najčešći su čimbenici koji otežavaju donošenje odluke poduzeća o pokretanju inovacijskih aktivnosti (Državni zavod za statistiku: "Inovacije u poduzećima u razdoblju 2016. – 2018.").

4. OKVIR I IZVORI FINANCIRANJA USMJERENI INOVACIJAMA

Novoosnovani poduzetnici nemaju povijest poslovanja niti poslovne rezultate te im je pristup financiranju od strane banaka ograničen. Banke su

vrlo nesklone riziku, što dovodi do toga da 79% malih i srednjih poduzetnika (u daljnjem tekstu: MSP) koristi vlastite prihode i zadržanu dobit kao svoj primarni izvor financiranja novih ulaganja (Šundalić i sur., 2018).

MSP-ovi imaju određene teškoće u pribavljanju malih zajmova pa tako 60% MSP-ova nema dovoljna jamstva za pribavljanje bilo kojeg oblika financiranja od banaka, a razina kamatnih stopa previsoka je za njih 34% (Operativni program konkurentnost i kohezija 2014. – 2020.).

Okvir za politike i programe relevantne za pokretanje poduzetničkog pothvata u području inovacija u RH obuhvaća još važeću Strategiju razvoja poduzetništva u RH 2013. – 2020., Industrijsku strategiju RH 2014. – 2020., Strategiju pametne specijalizacije RH (u daljnjem tekstu: Strategija S3) za razdoblje od 2016. do 2020. godine i Akcijski plan za provedbu Strategije S3 te Strategiju poticanja inovacija RH 2014. – 2020.

Usvojena Nacionalna razvojna strategija 2030. daje strateški smjer i okvir popratnih strateških i provedbenih resornih akata kao i provedbenog okvira fondova EU za razdoblje 2021. – 2027. te naglašava kako bi se ostvario snažniji gospodarski iskorak i povećao potencijal rasta, hrvatsko gospodarstvo mora povećati produktivnost i biti otvoreno prema novim idejama i internacionalizaciji (Nacionalna razvojna strategija Republike Hrvatske do 2030. godine).

Da bi se postigla međunarodna konkurentnost, potrebno je da MSP-ovi intenzivnije koriste informacijske i komunikacijske tehnologije te da rade na intenzivnijoj digitalnoj transformaciji. Zbog nedostatka sredstava inovativna poduzeća često ne mogu razvijati nove ideje. Mjere podrške ulaganjima u okviru Zakona o poticanju ulaganja usmjerene su na jačanje konkurentnosti gospodarstva RH kroz skup mjera među kojima su najznačajniji porezni poticaji. Mjere poticanja istraživanja i razvoja kroz Zakon o državnoj potpori za istraživačko-razvojne projekte kojima se za istraživačko-razvojne aktivnosti potpora pruža u obliku poreznih olakšica u cilju poticanja u aktivnosti razvoja i inovacija. Intenzitet potpore varira prema kategorijama istraživanja od 25% do 100% iznosa prihvatljivih troškova projekta (Vrednovanje učinka prioritetne osi 3 Poslovna konkurentnost Operativnog programa "Konkurentnost i kohezija" 2014. – 2020.).

Novoosnovana poduzeća s visokim potencijalom rasta u sektorima kao što su informacijska tehnologija, komunikacije i biotehnologija kao i poduzeća

koja imaju potencijal ostvariti visoke stope rasta tijekom razdoblja od 3 do 7 godina, predmet su ulaganja Fondova rizičnog kapitala. Prema provedenom istraživanju Gregorić i sur. "Važnost inovacija i poduzetništva za ekonomski razvoj Republike Hrvatske" kroz obuhvat i analizu 129 malih, srednji i velikih poduzetnika u Hrvatskoj daje se uvid problema s kojima se susreću poduzetnici u Hrvatskoj s aspekta inovacija, kreativnosti te značaja istih za njihov rast i razvoj. Gotovo trećina ispitanih poduzeća navela je kako je najveći izazov bilo prikupljanje kapitala.

Europski investicijski fond i Ministarstvo regionalnoga razvoja i fondova EU sklopili su 2018. godine Sporazum o financiranju kojim je ugovoren plasman ESIF Fond rizičnog kapitala – financijskog instrumenta koji će raspolagati vrijednošću od minimalno 42,5 milijuna eura. Instrument je usmjeren na ranije faze ulaganja u svrhu potpore razvoja hrvatskog start-up tržišta da bi se podržao daljnji razvoj poslovanja. Financijski instrumenti EU dostupni poduzetnicima u Hrvatskoj uključuju sredstva EIB i EIF sredstva u vidu kredita, u okviru InnovFin i EFSI sredstava plasiraju se krediti za sve sektore, IRI, start-up i ranu fazu u iznosu 187.000 – 56.250.000 milijuna kuna. Obzor 2020. daje mogućnosti financijske potpore MSP-ovima za inovacijske projekte, pristup suradnji s istraživačkim institucijama u velikim projektima i pristup financijskim instrumentima koji su namijenjeni tehnologijsko-inovativnim poduzećima. U okviru programa COSME MSP-ovima su na osnovi kombiniranog financiranja dostupni krediti u iznosu manjem od milijun kuna namijenjeni start-up poduzećima za financiranje ulaganja u novu opremu. Mjere potpore MSP-ovima u okviru Drugog projekta tehnologijskoga razvoja (STP II) uključuju mjere Provjere inovativnog koncepta (PoC) i Razvoja poduzeća koja se zasnivaju na znanju (RAZUM) (Vrednovanje učinka prioritetne osi 3 Poslovna konkurentnost Operativnog programa "Konkurentnost i kohezija" 2014. – 2020.).

5. BESPOVRATNE POTPORE IZ FONDOVA EU NOVOOSNOVANIM PODUZEĆIMA ZA RAZVOJ KROZ INOVACIJE

Povećanje konkurentnosti malog i srednjeg poduzetništva predstavlja i jedan od ciljeva Operativnog programa konkurentnost i kohezija koji se sufinancira iz Europskog fonda za regionalni razvoj i Kohezijskog fonda, a njegova se strategija temelji na koncentraciji ulaganja u devet tematskih

ciljeva zajedničkog Strateškog okvira i njihovim specifičnim investicijskim prioritetima, s daljnjom razradom na specifične ciljeve.

U okviru prioritetne osi 3 "*Poslovna konkurentnost*", jedan od prioriteta financiranja odnosi se na poboljšanje inovativnosti MSP-ova, kroz specifičan cilj 3d2 "*Povećana inovativnost MSP-ova*". Potpora ima za cilj izravno podržavati inovativna poduzeća koja su u svojoj poslovnoj aktivnosti usmjerena na napredne i inovativne proizvode i usluge visoke dodane vrijednosti.

Putem Poziva raspisanog 2016. godine, *Inovacije novoosnovanih MSP*, bespovratna sredstva namijenjena su za razvoj novoosnovanih poduzeća i uspješan prijenos inovativnih ideja novoosnovanih poduzetnika. Potpora podupire ulaganja neophodnih za primjenu rezultata istraživanja, razvoja i inovacija u poslovne aktivnosti i pokretanje proizvodnje na temelju primijenjenih rješenja. Prihvatljivi prijavitelji su pravne ili fizičke osobe koje su mikro, mala ili srednja poduzeća, osnovani najviše 36 mjeseci prije dana predaje projektne prijave i nisu raspodijelili dobit i nisu osnovani spajanjem. Najniži iznos po pojedinom poduzetniku iznosi 150.000,00 HRK, dok najviši iznos bespovratnih sredstava koji se može dodijeliti pojedinom poduzetniku iznosi 1.500.000,00 HRK, uz maksimalan intenzitet potpore u iznosu od 90%. Za financiranje su prihvatljive aktivnosti namijenjene razvoju inovacija koje trebaju rezultirati proizvodima koji su novost u ponudi poduzeća i/ili novost na tržištu.

Za novoosnovana poduzeća u ranim faza njihova razvoja, uz navedene bespovratne potpore, integrirana potpora osigurava se i u okviru financijskih instrumenata te potpornih institucija.

6. STUDIJE SLUČAJA NEKOLIKO ODABRANIH PODUZEĆA

U nastavku rada analizom dostupnih sekundarnih izvora podataka prikazane su četiri studije slučaja na prigodno odabranim poduzećima iz raznih područja djelovanja koje su koristile potpore iz Poziva *Inovacije novoosnovanih MSP* (Referentna oznaka Poziva: KK.03.2.2.01 od 9. svibnja 2016. godine).

Poziv je odabran s obzirom na to da je objavljen tijekom 2016. godine te je moguće pratiti rezultate poslovanja odabranih poslovnih subjekata, odnosno

povezanost dobivene potpore na razvoj novih proizvoda u odnosu na njihovo poslovanje.

Korištenjem podataka iz godišnjih financijskih izvještaja za promatrano razdoblje agregiranih i dohvaćenih kroz portal Fininfo.hr i Info.biz izdvojene su najrelevantnije stavke godišnjih financijskih izvještaja iz kojih se prati povezanost dodijeljene potpore na poslovanje društva odabranih studija slučaja.

Pokazatelji su uzeti u 6 kategorija: najvažniji financijski pokazatelji – bilanca, najvažniji financijski pokazatelji – račun dobiti i gubitka, pokazatelji ulaganja (bruto investicije, novostvorena vrijednost), pokazatelji profitabilnosti (ROA, ROE, EBITDA marža), pokazatelji zaposlenih, produktivnosti i prosječnih plaća.

7. STUDIJA SLUČAJA: AIRCASH D.O.O.

Društvu Aircash d.o.o., osnovanom 2015. godine, s osnovnom djelatnosti računalno programiranje, dodijeljeno je 445.500,00 HRK sredstava potpora. Opći cilj projekta je komercijalizacija inovativne ideje razvoja i puštanje u rad inovativne platforme za brzo i jednostavno slanje manjih iznosa gotovog novca između fizičkih osoba odnosno pružanje usluge gotovinskog platnog prometa kroz novoosnovano poduzeće Aircash d.o.o., a dodijeljena bespovratna sredstva usmjerena su na razvoj i testiranje dvaju dodatnih modula nužnih za ispunjavanje regulatornih uvjeta izvještavanja nadležnih institucija te interna i integracijska testiranja prije puštanja u rad. Razdoblje provedbe projekta bilo je 1. svibnja 2017. – 1. ožujka 2018. godine.

Subjekt djeluje u području Fintech industrije koja se vrlo snažno razvija na globalnoj razini. Aircash je hrvatska fintech kompanija koja je razvila mobilnu aplikaciju koja omogućuje brz i siguran prijenos novca između korisnika, fizičkih i pravnih osoba te je prva na hrvatsko tržište uvela digitalni novčanik. Aircash je aplikacija koja omogućuje korisnicima da spremne novac na svoj digitalni Aircash novčanik te potom koriste novac za plaćanje online usluga i proizvoda kod ovlaštenih partnera poput lutrije, igara na sreću, nadoplate ENC-a ili telekomunikacijskih usluga. Jednako tako, korisnici Aircash aplikacije mogu poslati novac na račun te taj isti novac podignuti u bilo kojoj poslovnici INA-e, Tiska (dostupan korisnicima na oko 1650 maloprodajnih mjesta INA-e i Tiska) ili na PBZ bankomatu u cijeloj Hrvatskoj. Inovativnost načina gotovinskih isplata ogleda se u

moгуćnosti podizanja novca u gotovini bez ikakve bankovne debitne/kreditne kartice, već se isplata izvršava pomoću unosa šesteroznamenkastog koda iz Aircash aplikacije.

Sredstva potpore isplaćena su iz državnog proračuna 2017. i 2018. godine.

Tablica 1. Pregled izvršenih plaćanja iz državnog proračuna poduzeća Aircash d.o.o.

<i>Isplatelj</i>	2017.	2018.	2019.	2020.
Ministarstvo gospodarstva, poduzetništva i obrta	247.149,69	180.349,95	-	-
Ukupni iznos	247.149,69	180.349,95	-	-

Izvor: vlastita izrada autora.

Tablica 2. Najznačajniji financijski pokazatelji – bilanca poduzeća Aircash d.o.o.

<i>Financijski pokazatelji - Bilanca</i>	2016.	2017.	2018.	2019.	2020.
Nematerijalna imovina	290.057	499.089	599.589	722.143	1.059.486
<i>Izdaci za razvoj</i>	290.057	298.057	0	0	0
<i>Koncesije, patenti, licencije, robne i uslužne marke, softver i ostala prava</i>	0	201.032	599.589	722.143	1.059.486
Odgodeno plaćanje troškova i prihod budućeg razdoblja	0	0	0	0	2.021.594

Izvor: vlastita izrada autora.

Nematerijalna imovina do 2018. godine narasla je za više od 100% u odnosu na stanje imovine potkraj 2016. godine, da bi do kraja 2020. godine narasla za otprilike 250% u odnosu na 2016. godinu kada je potpora primljena. Izdaci za razvoj u bilanci su evidentirani u 2016. i 2017. godini kada je platforma razvijana te puštena u rad, što je izravan utjecaj primljenih potpora. Rast vrijednosti Aircash platforme vidljiv je kroz bilancu od 2017. do 2020. godine u kojoj je dosegla knjigovodstvenu vrijednost od 1.059.486 HRK.

Tablica 3. Najznačajniji financijski pokazatelji – račun dobiti i gubitka poduzeća Aircash d.o.o.

<i>Financijski pokazatelji - RDG</i>	2016.	2017.	2018.	2019.	2020.
Prihodi od prodaje	140.000	370.373	1.471.950	5.039.314	27.454.292
<i>Prihodi od prodaje u zemlji</i>	<i>140.000</i>	<i>370.373</i>	<i>1.146.122</i>	<i>4.671.718</i>	<i>27.088.535</i>
<i>Prihodi od prodaje u inozemstvu</i>	<i>0</i>	<i>0</i>	<i>325.828</i>	<i>366.835</i>	<i>360.407</i>
Ostali financijski prihodi	0	247.150	180.524	11.500	7.605
EBITDA	46.492	-52.034	470.255	707.053	8.747.323
Dobit ili gubitak prije oporezivanja	46.596	194.965	644.790	546.210	8.407.821

Izvor: vlastita izrada autora.

Poslovni prihodi bilježe značajan rast. EBITDA je u 2017. godini negativna, što je i za očekivati zbog finalne faze testiranja proizvoda prije puštanja u rad, dok u idućem razdoblju bilježi rast. Dobit prije oporezivanja pokazuje trend rasta, te je s obzirom na djelatnost, u očekivanom omjeru u odnosu na poslovne prihode.


Tablica 4. Pokazatelji ulaganja poduzeća Aircash d.o.o.

<i>Financijski pokazatelji</i>	2016.	2017.	2018.	2019.	2020.
Bruto investicije u ostalu materijalnu imovinu i nematerijalnu imovinu (investicije u istraž. i razvoj, softver, baze podataka i dr.nemat. imovina)	290.057	298.057	599.589	39.787	1.390.203
Novostvorena vrijednost	93.811	248.848	921.674	1.379.726	10.147.667

Izvor: vlastita izrada autora.

Bruto investicije u nematerijalnu imovinu u 2016. i 2017. godini realizirane su u visini dobivene potpore, te su u 2018. godini rasle iz drugih izvora financiranja, sa značajnim padom u 2019. godini.

Graf 1. Pokazatelji profitabilnosti poduzeća Aircash d.o.o.



Izvor: vlastita izrada autora.

EBITDA marža je u 2017. godini negativna, dok u idućem razdoblju pokazuje trend rasta. Iako je 2019. godine 14,03%, profitabilnost društva veća je nego u 2018. godini zbog većih poslovnih prihoda. Smanjenje vrijednosti ROE ukazuje na povećanje konkurentnosti društva, s obzirom na to da se u 2018. i 2019. godini značajno povećala kapitaliziranost društva. ROA pokazuje isti trend s obzirom na to da se značajno povećala i imovina društva.

Tablica 5. Pokazatelji zaposlenih, produktivnosti i prosječnih plaća poduzeća Aircash d.o.o.

Pokazatelji	2016.	2017.	2018.	2019.	2020.
Broj zaposlenih prema satima rada	1	2	3	5	9
Prosječna neto plaća po zaposleniku	2.528	1.409	5.714	6.840	7.921
Poslovni prihodi po zaposlenom	140.000	185.187	490.650	1.007.863	3.050.477

Izvor: vlastita izrada autora.

Broj zaposlenih se povećao, kao i prosječna mjesečna bruto plaća. Poslovni prihod po zaposlenom je također rastao za više od 100%, što je jedan od glavnih pokazatelja produktivnosti, a samim time i porasta konkurentnosti društva.

Uvidom u dostupne podatke s mrežnih stranica (<https://aircash.eu/o-nama>), moguće je uočiti stabilan i trajan razvoj te širenje na hrvatsko i međunarodno tržište. Razvoj proizvoda krenuo je 2014. idejom o digitalnom slanju novca u Hrvatskoj i inozemstvu. Godine 2015. osnovana je tvrtka Aircash d.o.o. i okupljen tim za razvoj aplikacije, dok u razdoblju od 2016. do 2018. Aircash d.o.o. dobiva licencu HNB-a koja omogućuje platni promet na području EU, ugovorena je suradnja s najvećim hrvatskim tvrtkama te Aircash aplikacija izlazi na Google Play i iOS AppStore s uslugom trenutnog slanja i primanja novca preko mobitela u HR, ujedno dolazi do širenja usluga koje je moguće platiti iz Aircash aplikacije.

Godine 2019. Aircash d.o.o. ostvaruje licence za IEN, čime Aircash postaje prvi hrvatski digitalni e-novčanik, dolazi do povećanja broja partnera unutar HR, ali i u cijeloj EU, sklapa se suradnja s HAC-om (nadoplata ENC-a), Tiskom (Aircash uplata i isplata na svim kioscima Tiska u HR), suradnja s PBZ-om (inovativna usluga na hrvatskom tržištu – isplata novca na svim PBZ bankomatima) te je potpisana suradnja s jednom od najvećih svjetskih financijskih institucija za međunarodni transfer novca, tvrtkom RIA koja posluje u 155 zemalja, na 389 000 lokacija sa 100 različitih valuta zahvaljujući čemu Aircash aplikacija nudi i uslugu međunarodnog transfera novca. Godine 2020. uvedena je nova usluga kupovine PlayStation bonova, suradnja sa Zagrebparkingom (nova usluga plaćanja parkinga aplikacijom), kasnije su pridruženi i još neki gradovi, suradnja s A1 i Tomato, suradnja s Tele2 i nova usluga plaćanja računa skeniranjem barkoda, a nastavlja se i razvoj sigurnosnih elemenata (biometrija) i širenje poslovanja izvan granica HR unutar EU. Širenjem portfelja usluga, jamčenjem sigurnosti i povjerenja u uslugu te omogućavanjem usluga u Hrvatskoj i inozemstvu. Ulaganjima u razvoj aplikacije od 2016., uočljiv je trend razvoja i širenja portfelja usluga, snažna marketinška aktivnost te značajna komercijalizacija proizvoda na hrvatskom i inozemnom tržištu s povećanjem broja korisnika (prema dostupnim podacima s mrežne stranice Aircash d.o.o., aplikaciju koristi 150.000 korisnika).

Analizirajući okružje, Aircash d.o.o. nema konkurenata u Hrvatskoj, već na globalnoj razini, poput drugih popularnih digitalnih novčanika (Revoluta,

N26), što pridonosi značajnom rastu na Hrvatskom tržištu. Ujedno, Aircash d.o.o. je licencirana institucija za platni promet s odobrenjem izdanim od HNB-a validnim i na području EU te je upisan u EU registar institucija za elektronički novac od krovnog regulatora EBA (*European Banking Association*), što mu daje dodatnu snagu na širem tržištu.

8. STUDIJA SLUČAJA: LLOYDS DESIGN D.O.O.

Društvo Lloyds Design d.o.o., osnovano je 2014. godine, a specijalizirano je za web dizajn, development, izradu softwarea i mobilnih aplikacija. Na temelju Poziva dodijeljeno je 669.292,57 HRK potpora za razvoj inovativnog rješenja za poslovne sajmove "QR EXPO DIRECT". QR Expo Direct cjelovito je softversko rješenje koje bilježi sve interakcije na poslovnim sajmovima, ali i drugim business-to-business događanjima poput konferencija ili poslovnih skupova kroz jednostavno skeniranje QR koda na akreditaciji (<https://lider.media/aktualno/tvrtka-lloyds-design-iz-labina-razvila-je-inovativno-rjesenje-za-poslovne-sajmove-bez-vizitki-26709>).

Softverskim rješenjem QR EXPO DIRECT podiže se vrijednost, imidž i atraktivnost svim tipovima sajmove tako što organizatoru donosi vrijedne statističke podatke koji mu štede novac i vrijeme, te mu služe za optimizaciju budućih sajmove. Istodobno, izlagačima automatski kreira bazu potencijalnih poslovnih kontakata i kupaca, te vodi statistiku o aktivnosti prodajnog osoblja, a posjetiteljima olakšava skupljanje kontakata, posjetnica, kataloga i drugih materijala, automatski im u e-mail pretinac šaljući sve podatke o izložbenom mjestu koje su posjetili. Razvoj sustava trajao je od 30. listopada 2017. do 30. ožujka 2019. godine, a osim razvoja aplikacije i softvera rezultirao je otvaranjem novih radnih mjesta i povećanjem ulaganja u inovacije.

Sredstva potpore isplaćena su iz državnog proračuna 2017., 2018. i 2019. godine.

Tablica 6. Pregled izvršenih plaćanja iz državnog proračuna poduzeća Lloyds Design d.o.o.

<i>Isplatiatelj</i>	<i>2017.</i>	<i>2018.</i>	<i>2019.</i>	<i>2020.</i>
Ministarstvo gospodarstva, poduzetništva i obrta	133.858,51	266.507,78	246.247,17	-
Ukupni iznos	133.858,51	266.507,78	246.247,17	-

Izvor: vlastita izrada autora.

Tablica 7. Najznačajniji financijski pokazatelji – bilanca poduzeća Lloyds Design d.o.o.

<i>Financijski pokazatelji - Bilanca</i>	<i>2016.</i>	<i>2017.</i>	<i>2018.</i>	<i>2019.</i>	<i>2020.</i>
Nematerijalna imovina	42.332	161.283	692.816	974.359	778.509
<i>Izdaci za razvoj</i>	<i>30.550</i>	<i>0</i>	<i>0</i>	<i>0</i>	<i>0</i>
<i>Koncesije, patenti, licencije, robne i uslužne marke, softver i ostala prava</i>	<i>11.782</i>	<i>5.266</i>	<i>2.153</i>	<i>685.250</i>	<i>479.157</i>
<i>Nematerijalna imovina u pripremi</i>	<i>0</i>	<i>156.017</i>	<i>690.663</i>	<i>289.109</i>	<i>299.352</i>
Odgodeno plaćanje troškova i prihod budućeg razdoblja	1.126	689.835	683.375	546.888	442.811

Izvor: vlastita izrada autora.

U odnosu na 2016. godinu odnosno razdoblje prije dobivanja potpore, vidljiv je značajno manji udio nematerijalne imovine u bilanci poduzeća, koji se povećavao u razdoblju od 2017. do 2020. sukladno dobivenim potporama. U skladu s dobivenim potporama u bilanci je softversko rješenje iskazano kao materijalna imovina u pripremi za vrijeme dok je projekt bio u fazi razvoja softverskog rješenja. Sukladno završetku softverskog rješenja imovina u pripremi stavljena je u upotrebu te na navedeni način iskazana u bilanci. Trend kretanja dobivenih potpora slijede i iskazani prihodi budućeg razdoblja.

Tablica 8. Najznačajniji financijski pokazatelji – račun dobiti i gubitka poduzeća Lloyds Design d.o.o.

<i>Financijski pokazatelji - RDG</i>	2016.	2017.	2018.	2019.	2020.
POSLOVNI PRIHODI	675.576	1.098.371	2.520.936	3.531.769	4.097.982
<i>Prihodi od prodaje u zemlji</i>	634.333	805.880	1.119.928	2.196.985	2.253.271
<i>Prihodi od prodaje u inozemstvu</i>	4.494	162.612	804.948	897.381	1.045.804
<i>Prihodi na temelju upotrebe vlastitih proizvoda, robe i usluga</i>	30.550	125.467	519.999	191.596	0
<i>Ostali poslovni prihodi</i>	6.199	4.412	76.061	245.807	798.907
EBITDA	114.833	205.752	355.452	357.962	915.298
Dobit ili gubitak prije oporezivanja	95.357	162.055	306.195	140.273	561.520

Izvor: vlastita izrada autora.


U promatranom razdoblju poslovni prihodi pokazuju trend rasta. EBITDA je pozitivna, te također bilježi rast. Društvo posluje s dobiti, koja do 2018. godine ima trend rasta. U 2019. godini je manja nego prethodne godine zbog veće amortizacijske stope i iznosa obračunate amortizacije.

Tablica 9. Pokazatelji ulaganja poduzeća Lloyds Design d.o.o.

<i>Financijski pokazatelji</i>	2016.	2017.	2018.	2019.	2020.
Bruto investicije u ostalu materijalnu imovinu i nematerijalnu imovinu (investicije u istraž. i razvoj, softver, baze podataka i dr.nemat. imovina)	126.661	125.467	514.535	2.201.622	192.966
Novostvorena vrijednost	238.871	592.828	1.462.552	2.171.127	3.294.917

Izvor: vlastita izrada autora.

Bruto investicije u nematerijalnu imovinu najznačajnije su porasle u 2018. i 2019. godini kada je isplaćen najznačajniji dio potpora. Novostvorena vrijednost kontinuirano je rasla u razdoblju dobivenih potpora te je nastavila navedeni trend i u 2020. godini.

Graf 2. Pokazatelji profitabilnosti poduzeća Lloyds Design d.o.o.

Izvor: vlastita izrada autora.

EBITDA marža je više nego zadovoljavajuća u promatranom razdoblju, te je vidljivo da se profitabilnost društva uvećava. ROE ima najveću vrijednost u 2015. godini, kada je kapitaliziranost društva najmanja. Smanjenje vrijednosti navedenog pokazatelja ukazuje na povećanje konkurentnost društva. ROA pokazuje isti trend, s obzirom na to da se zbog ulaganja značajno povećala i ukupna imovina društva.

Tablica 10. Pokazatelji zaposlenih, produktivnosti i prosječnih plaća poduzeća Lloyds Design d.o.o.

<i>Pokazatelji</i>	<i>2016.</i>	<i>2017.</i>	<i>2018.</i>	<i>2019.</i>	<i>2020.</i>
Broj zaposlenih prema satima rada	2	5	8	12	16
Prosječna neto plaća po zaposleniku	3.031	4.068	5.313	7.371	7.183
Poslovni prihodi po zaposlenom	337.788	219.674	315.117	294.314	256.124

Izvor: vlastita izrada autora.

Broj zaposlenih se povećao, kao i prosječna mjesečna neto plaća. Poslovni prihod po zaposlenom u promatranom razdoblju varira iz godine u godinu, što ukazuje na različite profile zaposlenih i povećanje broja zaposlenih na različitim radnim mjestima. Značajno je opaziti kako je u pandemijskoj 2020. godini došlo do povećanja broja zaposlenih unatoč izazovima u organizaciji sajмова i poslovnih događaja.

Sustav QR Expo Direct predstavljen je domaćem i međunarodnom tržištu, a sukladno dostupnim podacima pretraživanjem mrežnih stranica (<https://www.poslovni.hr/sci-tech/poslovni-sajmovi-bez-vizitki-vrijeme-je-351519>), testiran je i na nekoliko raznolikih poslovnih događanja s potencijalom široke primjene. Kao prepoznati investitori za komercijalizaciju aplikacije su organizatori sajмова i drugih poslovnih događaja kojima se daje uvid u brojne korisne podatke, stvarajući, u realnom vremenu, iznimno vrijednu bazu informacija u cilju optimizacije sajma/poslovnog događaja.

9. STUDIJA SLUČAJA: CLOUDONIA D.O.O.

Cloudonia d.o.o., društvo registrirano 2016. godine, za obradu podataka, usluge poslužitelja i djelatnosti povezane s njima. Projekt razvija potpuno novu softversku aplikaciju MADIBU ANALYTICA (Manufacturer – Distributor – Buyer Analytica) koja će prikupljati, obrađivati, analizirati i dostavljati podatke i izvještaje o proizvodima prodanim u određenom razdoblju, na određenom području, određenim kupcima.

Aplikacija tržištu pruža inovativne usluge i omogućuje poduzećima pravodobnu, točnu i kvalitetnu informaciju potrebnu za planiranje i proizvodnju optimalnih količina proizvoda potrebnih tržištu. Provedba projekta trajala je od 1. rujna 2017. do 1. ožujka 2019. godine. Za projekt MADIBU ANALYTICA dodijeljeno je 1.450.000,00 HRK sredstava.

Ministarstvo gospodarstva, poduzetništva i obrta ostvarenu potporu isplatilo je u razdoblju od 2017. do 2019. godine.

Tablica 11. Pregled izvršenih plaćanja iz državnog proračuna poduzeća Cloudonia d.o.o.

<i>Isplatiatelj</i>	<i>2017.</i>	<i>2018.</i>	<i>2019.</i>	<i>2020.</i>
Ministarstvo gospodarstva, poduzetništva i obrta	290.000,00	18.455,99	850.150,94	-
Ukupni iznos	133.858,51	266.507,78	246.247,17	-

Izvor: vlastita izrada autora.

Tablica 12. Najznačajniji financijski pokazatelji – bilanca poduzeća Cloudonia d.o.o.

<i>Financijski pokazatelji - Bilanca</i>	<i>2016.</i>	<i>2017.</i>	<i>2018.</i>	<i>2019.</i>	<i>2020.</i>
Nematerijalna imovina	250.171	250.171	1.094.448	2.861.327	4.153.310
<i>Izdaci za razvoj</i>	<i>250.171</i>	<i>250.171</i>	<i>1.094.448</i>	<i>2.734.403</i>	<i>3.897.435</i>
<i>Nematerijalna imovina u pripremi</i>	<i>0</i>	<i>0</i>	<i>0</i>	<i>126.924</i>	<i>255.875</i>
Odgodeno plaćanje troškova i prihod budućeg razdoblja	50	120	112.392	608.878	416.601

Izvor: vlastita izrada autora.

Nematerijalna imovina društva bilježi značajan trend rasta u 2018., 2019. i 2020. godini, odnosno u godinama nakon dobivanja državne potpore. Najveći dio te imovine odnosi se na izdatke za razvoj s obzirom na to da se radi o izdacima za razvoj potpuno nove softverske aplikacije.

Tablica 13. Najznačajniji financijski pokazatelji – račun dobiti i gubitka poduzeća Cloudonia d.o.o.

<i>Financijski pokazatelji - RDG</i>	<i>2016.</i>	<i>2017.</i>	<i>2018.</i>	<i>2019.</i>	<i>2020.</i>
POSLOVNI PRIHODI	24.400	134.867	804.195	2.635.777	2.352.008
<i>Prihodi od prodaje u zemlji</i>	<i>24.400</i>	<i>121.000</i>	<i>398.891</i>	<i>1.876.722</i>	<i>1.748.091</i>
<i>Prihodi od prodaje u inozemstvu</i>	<i>0</i>	<i>0</i>	<i>0</i>	<i>0</i>	<i>0</i>
<i>Prihodi na temelju upotrebe vlastitih proizvoda, robe i usluga</i>	<i>0</i>	<i>0</i>	<i>378.137</i>	<i>247.903</i>	<i>385.956</i>
<i>Ostali poslovni prihodi</i>	<i>0</i>	<i>13.867</i>	<i>27.167</i>	<i>511.151</i>	<i>217.961</i>
EBITDA	-17.711	480	283.649	896.492	1.001.905
Dobit ili gubitak prije oporezivanja	-17.711	476	277.437	36.528	19.481

Izvor: vlastita izrada autora.

Poslovni prihodi pokazuju trend rasta do 2019., a u 2020. godini padaju na 2.352.000 HRK u odnosu na ostvarenih 2.635.777 HRK u 2019. godini. EBITDA je pozitivna te ima trend rasta. U 2017. društvo je poslovalo pozitivno, ali s minimalnom dobiti. U 2018. dobit je značajno porasla, dok je u 2019. godini manja za 87%, ponajprije zbog obračuna amortizacije na dugotrajnu imovinu.


Tablica 14. Pokazatelji ulaganja poduzeća Cloudonia d.o.o.

<i>Financijski pokazatelji</i>	<i>2016.</i>	<i>2017.</i>	<i>2018.</i>	<i>2019.</i>	<i>2020.</i>
Bruto investicije u ostalu materijalnu imovinu i nematerijalnu imovinu (investicije u istraž. i razvoj, softver, baze podataka i dr.nemat. imovina)	0	0	844.276	2.314.782	1.949.465
Novostvorena vrijednost	36.116	115.328	668.886	1.508.188	1.612.524

Izvor: vlastita izrada autora.

S obzirom na to da u 2017. i 2018. godini nije bilo bruto investicija u nematerijalnu imovinu, evidentna je povezanost dobivenih državnih potpora na bruto investicije i novostvorenu vrijednost društva koja pokazuje trend rasta tijekom cijelog promatranog razdoblja, a posebice u 2019. godini kada su i bruto investicije u nematerijalnu imovinu bile najznačajnije.

Graf 3. Pokazatelji profitabilnosti poduzeća Cloudonia d.o.o.



Izvor: vlastita izrada autora.

EBITDA marža je više nego zadovoljavajuća te je vidljivo povećanje profitabilnosti društva svake godine. ROE ima najveću vrijednost u 2018. godini zbog velike dobiti iz ukupnog poslovanja, i niske kapitaliziranosti društva. Smanjenje u 2019. godini rezultat je manje dobiti poslovne godine i veće kapitaliziranosti društva. ROA pokazuje isti trend, s obzirom na to da se zbog ulaganja povećala ukupna imovina društva, te je veća neto dobit ostvarena u 2018. u odnosu na neto dobit u 2019. godini.

Tablica 15. Pokazatelji zaposlenih, produktivnosti i prosječnih plaća poduzeća Cloudonia d.o.o.

<i>Pokazatelji</i>	<i>2016.</i>	<i>2017.</i>	<i>2018.</i>	<i>2019.</i>	<i>2020.</i>
Broj zaposlenih prema satima rada	1	1	1	3	3
Prosječna neto plaća po zaposleniku	1.700	5.296	16.730	9.958	10.667
Poslovni prihodi po zaposlenom	24.400	134.867	804.195	878.592	784.003

Izvor: vlastita izrada autora.

Broj zaposlenih se povećao, kao i prosječna mjesečna neto plaća. Poslovnih prihod po zaposlenom je porastao, što je jedan od glavnih pokazatelja produktivnosti, a time i konkurentnosti društva.

Proizvođači i distributeri prodaju svoju robu, ali informacije o krajnjem kupcu, tržišnim udjelima i točnoj prodaji na svakoj lokaciji su ili nepostojeći ili se kupuju u malim setovima te često rezultiraju nepouzdanim projekcijama. Upravo su ti podaci ključni za cijeli niz strateških aktivnosti – od planiranja zaliha i poslovanja do marketinških aktivnosti i razvoja novih proizvoda, stoga je razvijena aplikacija zapravo alat za monetizaciju prikupljenih podataka koji za proizvođače i distributere imaju stratešku vrijednost. Prema dostupnim podacima pretraživanjem mrežnih stranica (<https://www.cloudonia.eu> i <https://lider.media/poslovna-scena/tehnopolis/do-pravovremenih-izvjestaja-o-prodaji-u-maloprodajnom-lancu-uz-aplikaciju-hrvatske-start-up-tvrtke-cloudonia-37444>), aplikacija je primarno namijenjena proizvodnim tvrtkama čiji se proizvodi prodaju u maloprodaji i kanalu HoReCa, dakle proizvodnji hrane i pića, odnosno robi široke potrošnje. Detaljni podaci o prodanim proizvodima su od izuzetne važnosti, ali dosad nije postojalo rješenje koje bi eliminiralo problem nestandardiziranih softverskih rješenja i nestandardiziranih označavanja artikala u različitim poduzećima. Razvijeno rješenje klijentima poboljšava planiranje i proizvodnju te cilja na značajan utjecaj na efikasnost, a shodno tomu i na konkurentnost tvrtke koja će raspolagati podacima i uvidima koji su sposobni promijeniti nabavnu strategiju.

Prema istraživanju PwC-a predviđa se da će umjetna inteligencija 2030. godine pridonijeti globalnom gospodarstvu s 15,7 bilijuna američkih dolara, a više od polovice te AI gospodarske dobiti očekuje na projektima vezanima za poboljšanja na području produktivnosti rada.

Dodatno, s obzirom na trendove i projekt u prethodno opisanom području, za očekivati je daljnju komercijalizaciju razvijene aplikacije u kratkom vremenu, tim više što društvo djeluje u sklopu snažne grupacije *Megatrend poslovna rješenja*, tvrtke koja uspješno posluje na tržištu više od 30 godina s usmjerenjem na usluge u području umjetne inteligencije i znanosti o podacima.

10. STUDIJA SLUČAJA: ADOPTOTECH D.O.O.

Adoptotech d.o.o., poduzeće je za računalno programiranje, registrirano 2015. godine, s iznosom dodijeljenih sredstava 1.049.546,86 HRK. Projekt za koji je dobivena potpora odnosi se na razvoj alata *TalentLyft* koji nudi inovativne tehnike za pronalazak kandidata, poput programa preporuka, društvenih mreža i napredne web tražilice. Cilj aplikacije je pomoći zaposlenima, stručnjacima za ljudske resurse i vlasnicima malih tvrtki u skladu s novim trendovima i tehnologijama u pronalaženju, privlačenju i zapošljavanju najboljih talenata za njihova otvorena radna mjesta. Alat prikupljanja i pohranjuje velike količine podataka, sadrži algoritam za određivanje tipa osobnosti pojedinca na temelju javno dostupnih podataka, te sustav za obradu podataka i komunikaciju s pasivnim kandidatima koji čine 78% današnjeg tržišta. Alat će omogućiti poduzećima da unaprijede i skrate proces zapošljavanja i da što efikasnije zaposle najkvalitetniji kadar koji se na tržištu zadržava u prosjeku 12 dana.

Ministarstvo gospodarstva, poduzetništva i obrta potporu je društvu isplatilo u razdoblju od 2017. do 2019. godine. Ministarstvo regionalnoga razvoja i fondova EU potporu je isplatilo u 2017. i 2018. godini.

Tablica 16. Pregled izvršenih plaćanja iz državnog proračuna poduzeća Adoptotech d.o.o.

<i>Isplatelj</i>	2017.	2018.	2019.	2020.
Ministarstvo gospodarstva, poduzetništva i obrta	209.909,37	488.180,55	793.384,27	-
Ministarstvo regionalnog razvoja i fondova EU	25.000,00	24.177,63	-	-
Ukupni iznos	234.909,37	512.358,18	793.384,27	-

Izvor: vlastita izrada autora.

Tablica 17. Najvažniji financijski pokazatelji – bilanca poduzeća Adoptotech d.o.o.

<i>Financijski pokazatelji - Bilanca</i>	2016.	2017.	2018.	2019.	2020.
Nematerijalna imovina	250.171	250.171	1.094.448	2.861.327	4.153.310
<i>Izdaci za razvoj</i>	250.171	250.171	1.094.448	2.734.403	3.897.435
<i>Nematerijalna imovina u pripremi</i>	0	0	0	126.924	255.875
Odgodeno plaćanje troškova i prihod budućeg razdoblja	50	120	112.392	608.878	416.601

Izvor: vlastita izrada autora.

Nematerijalna imovina u bilanci društva bilježi značajan porast od 2018. godine, odnosno godinu nakon početka dobivanja potpore, što je izravna povezanost dobivenih potpora. Navedeni trend rasta dugotrajne nematerijalne imovine u bilanci nastavlja se i nakon prestanka dobivanja potpore, što je vidljivo iz pokazatelja za 2020. godinu. Prihod budućeg razdoblja evidentiran je na temelju dobivenih potpora iz državnog proračuna najvećim dijelom u 2019. godini.

Tablica 18. Najvažniji financijski pokazatelji – račun dobiti i gubitka poduzeća Adoptotech d.o.o.

<i>Financijski pokazatelji - RDG</i>	2016.	2017.	2018.	2019.	2020.
POSLOVNI PRIHODI	24.400	134.867	804.195	2.635.777	2.352.008
<i>Prihodi od prodaje u zemlji</i>	24.400	121.000	398.891	1.876.722	1.748.091
<i>Prihodi od prodaje u inozemstvu</i>	0	0	0	0	0
<i>Prihodi na temelju upotrebe vlastitih proizvoda, robe i usluga</i>	0	0	378.137	247.903	385.956
<i>Ostali poslovni prihodi</i>	0	13.867	27.167	511.151	217.961
EBITDA	-17.711	480	283.649	896.492	1.001.905
Dobit ili gubitak prije oporezivanja	-17.711	476	277.437	36.528	19.481

Izvor: vlastita izrada autora.

Poslovni prihodi pokazuju trend rasta. EBITDA je pozitivna u 2017. i 2018., dok je prema financijskim izvještajima u 2019. godini negativna. Negativna operativna dobit rezultat je omaške u evidentiranju prihoda od dodijeljene potpore u 2019. godini. Ostali poslovni prihodi u 2017. i 2018. godini odnose se na dodijeljena bespovratna sredstva na temelju Poziva, dok je u 2019. godini dodijeljena potpora evidentirana kao financijski prihod, umjesto kao ostali poslovnih prihodi. Društvo posluje s dobiti, koja do 2018. godine ima trend rasta. U 2019. godini je manja nego prethodne godine, ponajprije zbog veće amortizacijske stope i iznosa obračunate amortizacije.


Tablica 19. Pokazatelji ulaganja poduzeća Adoptotech d.o.o.

<i>Financijski pokazatelji</i>	2016.	2017.	2018.	2019.	2020.
Bruto investicije u ostalu materijalnu imovinu i nematerijalnu imovinu (investicije u istraž. i razvoj, softver, baze podataka i dr.nemat. imovina)	0	0	844.276	2.314.782	1.949.465
Novostvorena vrijednost	36.116	115.328	668.886	1.508.188	1.612.524

Izvor: vlastita izrada autora.

S obzirom na to da u 2016. i 2017. godini nije bilo bruto investicija u nematerijalnu imovinu, evidentna je povezanost dobivenih državnih potpora na bruto investicije i novostvorenu vrijednost društva koja pokazuje trend rasta tijekom cijelog promatranog razdoblja, a počevši od 2019. godine kada su i bruto investicije u nematerijalnu imovinu bile najznačajnije. Novostvorena vrijednost bilježi rast u cijelom promatranom razdoblju.

Graf 4. Pokazatelji profitabilnosti poduzeća Adoptotech d.o.o.



Izvor: vlastita izrada autora.

EBITDA marža je više nego zadovoljavajuća u promatranom razdoblju, te je vidljivo povećanje profitabilnosti društva. Negativna EBITDA marža u 2019. nije zbog pada profitabilnosti poslovanja, već zbog krivog evidentiranja prihoda od dodijeljene potpore. ROE ima najveću vrijednost u 2018. godini zbog dobiti iz ukupnog poslovanja i niske kapitaliziranosti društva. Smanjenje u 2019. godini rezultat je manje dobiti poslovne godine i veće kapitaliziranosti društva. ROA pokazuje isti trend u promatranom razdoblju, s obzirom na to da se zbog ulaganja povećala i ukupna imovina društva, te je veća neto dobit ostvarena u 2018., u odnosu na neto dobit u 2019. godini.

Tablica 20. Pokazatelji zaposlenih, produktivnosti i prosječnih plaća poduzeća Adoptotech d.o.o.

<i>Pokazatelji</i>	<i>2016.</i>	<i>2017.</i>	<i>2018.</i>	<i>2019.</i>	<i>2020.</i>
Broj zaposlenih prema satima rada	1	1	1	3	3
Prosječna neto plaća po zaposleniku	1.700	5.296	16.730	9.958	10.667
Poslovni prihodi po zaposlenom	24.400	134.867	804.195	878.592	784.003

Izvor: vlastita izrada autora.

Broj zaposlenih se povećao, kao i prosječna mjesečna neto plaća. Poslovni prihod po zaposlenom rastao je do 2018., dok je u 2019. godini manji te je pretpostavka da je povećan broj zaposlenih na različitim radnim mjestima.

Kako je navedeno u prijavi projekta (<https://www.talentlyft.com/hr/eu-projekt>), projekt predstavlja stratešku polazišnu točku za daljnji razvoj i povećanje konkurentnosti Korisnika. Po iskorištenju potpore i razvojem sustava, projekt je postao potpuno prepoznatljiv što je vidljivo iz liste uspješnih priča dostupnih na web stranicama subjekta (<https://www.talentlyft.com/hr/customers>), a zamjetan je respektabilan portfelj referenci poput kompanija Nanobit, Rimac Automobili, Poliklinka Bagatin, Konzum, iOLAP. Iz opisanih iskustava navodi se prednost proizvoda kroz cjelovitost i pomoći u regrutaciji i zapošljavanju, ušteda u vremenu na administrativnim zadacima, pojednostavnjenje i ubrzavanje cjelokupnog procesa selekcije, privlačenje visokokvalitetnih kandidata kroz olakšanu komunikaciju brenda poslodavca. Dobitnici su nekoliko certifikata koji dokazuju kvalitetu i prepoznatljivost proizvoda na tržištu (npr. Rising star 2019. i sl.). Nastavno na navedeno, razvidan je značajan potencijal komercijalizacije i širenja na domaćem i međunarodnom okružju, a na što ukazuju u sadašnji financijski pokazatelji.

Iz analize poslovnih slučajeva vidljivo je kako sva četiri proučavana, novoosnovana poduzeća bilježe porast kako u broju zaposlenih, prihodima po zaposlenom, bruto plaći tako i u ključnim financijskim pokazateljima profitabilnosti. Dobivene potpore utjecale su pozitivno na financijski rast poduzeća i komercijalizaciju razvijenih proizvoda.

Istraživanjem je zaključeno kako su potpore pozitivno utjecale na rast poduzeća te su potpore učinkoviti izvor financiranja pri pokretanju inovativnih poduzeća te su odgovori na oba istraživačka pitanja pozitivni.

11. ZAKLJUČAK

Povezivanje znanosti i gospodarstva temelj je postizanja inovativnoga gospodarstva, u kojem se inovativne ideje pretvaraju u proizvode i usluge, generirajući ekonomski rast i zapošljavanje. Nedostatak izvora financijskih sredstava smatra se jednim od glavnih ograničenja u razvoju zato što novoosnovana poduzeća ne raspolažu zadržanom dobiti za financiranje razvojnih projekata. Raznim oblicima i izvorima financiranja te normativnim okvirom stvoreno je stabilno prateće investicijsko okružje, a prateće državne politike stabilan su oslonac novoosnovanim inovativnim poduzećima.

Bespovratna sredstva podržavaju projekte usmjerene na inovativnost i dodatnu vrijednost na regionalnoj, nacionalnoj ili međunarodnoj razini i/ili kapacitet za stvaranje održivog zapošljavanja. Bespovratnim sredstvima podržavaju se kapaciteti novoosnovanih MSP-ova za uvođenje inovacija obuhvaćajući ulaganja u provedbu novih rješenja.

Praćenjem pokazatelja na primjeru četiri poduzetnika, korisnika potpora, utvrđeno je da su ostvarili prihode i rast ključnih pokazatelja kao rezultat dodijeljene potpore te su stoga predviđene potpore učinkoviti izvor financijskih sredstava za novoosnovana poduzeća pri pokretanju inovativnih ulaganja.

Novoosnovana poduzeća imaju znatnu priliku korištenja bespovratnih sredstva fondova EU kroz primjenu visokorazvijenih tehnologija usmjerenih na razvoj visokokvalitetne robe/usluge s dodanom vrijednošću za industrije u kojima Hrvatska ima konkurentne prednosti. Također imaju priliku unaprijediti svoju, ali i konkurentnost gospodarstva u cjelini, što će dovesti do razvoja gospodarstva temeljenog na znanju, a čiji nositelji su novoosnovana brzorastuća inovativna poduzeća, poglavito u postcovid razdoblju koje predstoji.

DOPRINOS RADA

Bespovratna sredstva iz fondova EU u budućoj perspektivi jedan su od značajnih izvora financiranja malih (agilnih) novoosnovanih poduzeća koja se suočavaju sa izazovima dohvata sredstva za ulaganje u visokorizične poduzetničke pothvate inovacija i/ili unaprjeđenja proizvoda, usluga ili poslovnih modela. Kroz EU višegodišnji financijski okvir (VFO) te novi

izvor "EU sljedeće generacije (*Next Generation EU*)" za kojim se pokazala potreba usred krize uzrokovane koronavirusom, u razdoblju 2021. – 2027. za Republiku Hrvatsku je na raspolaganju više od 25 milijardi eura. Dio od navedenih sredstava namijenjen je jačanju konkurentnosti gospodarstva kroz ulaganja u infrastrukturu; istraživanje i inovacije, produktivna ulaganja u MSP-ove i sl.

Ovaj rad može poslužiti nositeljima javnih politika i tijelima u sustavu upravljanja i kontrole korištenja fondova EU o smjeru i sadržaju potrebnog raspisivanja Poziva za dodjelu bespovratnih sredstva za projekte novoosnovanih MSP-ova s ciljem poticanja njihovih ulaganja u područja istraživanja i razvoja proizvoda, usluga te inovativnih modela poslovanja s obzirom na utvrđenje komercijalnog uspjeha i uspješnih rezultata poslovanja odabranih poslovnih slučajeva koji su analizirani u radu.

LITERATURA

Aircash d.o.o., O nama. Dostupno dana 12.9.2021. na: <https://aircash.eu/o-nama>

CEPOR. Izvješće o malim i srednjim poduzećima u Hrvatskoj – 2019., Zagreb, 2019. ISSN 1848-3526. Dostupno dana 20.2.2021. na: <http://www.cepor.hr/wp-content/uploads/2015/03/SME-REPORT-2019-HR-WEB.pdf>

Cloudonia. Dostupno dana 12.9.2021. na: <https://www.cloudonia.eu/>

Državni zavod za statistiku. "Inovacije u poduzećima u razdoblju 2016. – 2018.", broj: 8.2.5., Zagreb, 30.9.2020., dostupno na: https://www.dzs.hr/Hrv_Eng/publication/2020/08-02-05_01_2020.htm

Ministarstva gospodarstva i održivog razvoja: prikazani podaci o osnivanju trgovačkih društava (d.o.o. i j.d.o.o.) i obrta u Republici Hrvatskoj, prema podacima iz sudskog i obrtnog registra. Preuzeto s: <https://start.gov.hr/st/broj-osnivanja.html> (Datum pristupa: 15.4.2021.)

Đulabić, V. (2014). 'Kohezijska politika Europske unije kao instrument razvoja Hrvatske', *Političke analize*, 5(17), str. 17-22. Preuzeto s: <https://hrcak.srce.hr/142493> (Datum pristupa: 26.3.2021.)

Gregorić, M., Hegeduš, I. i Kolenko, K. (2018). 'Važnost inovacija i poduzetništva za ekonomski razvoj Republike Hrvatske', *Obrazovanje za poduzetništvo – E4E*, 8 (Special issue/Posebno), str. 23-43. Preuzeto s: <https://hrcak.srce.hr/196926> (Datum pristupa: 26.3.2021.)

Lider media. Do pravovremenih izvještaja o prodaji u maloprodajnom lancu uz aplikaciju hrvatske start-up tvrtke Cloudonia. Dostupno dana 13.9.2021. na: <https://lider.media/poslovna-scena/tehnopolis/do-pravovremenih-izvjestaja-o-prodaji-u-maloprodajnom-lancu-uz-aplikaciju-hrvatske-start-up-tvrtke-cloudonia-37444>

Lider media. Tvrtka Lloyds design iz Labina razvila je inovativno rješenje za poslovne sajmove bez vizitki. Dostupno dana 13.9.2021. na: <https://lider.media/aktualno/tvrtka-lloyds-design-iz-labina-razvila-je-inovativno-rjesenje-za-poslovne-sajmove-bez-vizitki-26709>

Marinac, A., Devčić, A. i Raguž, V. (2014). Regionalni razvoj Hrvatske u sklopu kohezijske politike Europske unije u financijskoj perspektivi 2014. – 2020. *International Conference "Vallis Aurea" Focus on: Regional &*

Innovation Development / Katalinić, Branko (ur.). Požega: Veleučilište u Požegi; DAAAM International Vienna, str. 375-383

Ministarstvo gospodarstva i održivog razvoja. Operativni program konkurentnost i kohezija 2014. – 2020. Preuzeto s: https://www.mingo.hr/public/investicije/OPKK_2014_2020_31316.pdf (Datum pristupa: 18.3.2021.)

Nacionalna razvojna strategija Republike Hrvatske do 2030. godine. Preuzeto s: https://narodne-novine.nn.hr/clanci/sluzbeni/2021_02_13_230.html (Datum pristupa: 8.3.2021.)

Poslovni.hr, Sci-tech, Poslovni sajmovi bez vizitki vrijeme je. Dostupno dana 12.9.2021. na: <https://www.poslovni.hr/sci-tech/poslovni-sajmovi-bez-vizitki-vrijeme-je-351519>

Prohaska, Z. i Olgić Draženović, B. (2005). *Programi financiranja malih i srednjih poduzeća u Republici Hrvatskoj*. International Conference Entrepreneurship and Macroeconomic Management: Conference Proceedings. Vol. 2 / Križman Pavlović, Danijela (ur.). Pula: Faculty of Economics and Tourism. str. 605-617.

Šundalić, A., Zamić K., Sudatić, T., Pavić, Ž., Janković, D., Dremel, A. i Krivokapić, N. (2018). Sudbina otvorenih granica: zbornik radova sa znanstvenog skupa Globalizacija i regionalni identitet 2018., Osijek: Filozofski fakultet u Osijeku, Poljoprivredni fakultet u Osijeku, Poljoprivredni fakultet u Novom Sadu, Filozofski fakultet Univerziteta Crne Gore

Talently. EU projekt. Dostupno dana 12.9.2021. na: <https://www.talentlyft.com/hr/eu-projekt>

Talently. Costumers. Dostupno dana 13.9.2021. na: <https://www.talentlyft.com/hr/customers>

Trček, S. (2016). Smernice vrednotenja evropske kohezijske politike. *Revija za ekonomske in poslovne vede*, volume 3, issue 2, str. 3-19.

Vrednovanje učinka prioritetne osi 3 Poslovna konkurentnost Operativnog programa "Konkurentnost i kohezija" 2014-2020. Dostupno dana 7.3.2021. na: https://struktturnifondovi.hr/wp-content/uploads/2019/09/Zavr%C5%A1no-izvje%C5%A1%C4%87e_Vrednovanje-u%C4%8Dinka-PO3.pdf

Vukičević, A. i Živković, L. (2019). 'Aspekti razvoja inovacijskog poduzetništva u Republici Hrvatskoj', Zbornik radova Veleučilišta u Šibeniku, (3-4/2019), str. 41-51. Preuzeto s: <https://hrcak.srce.hr/235542> (Datum pristupa: 27.3.2021.)

THE IMPACT OF SUPPORT TO NEWLY ESTABLISHED COMPANIES FOR INNOVATION AND DEVELOPMENT OF NEW PRODUCTS AND SERVICES THROUGH EU FUNDS IN THE REPUBLIC OF CROATIA

Abstract

One of the significant challenges of start-ups is to raise funds for the realization and commercialization of entrepreneurial ideas. Ever since 2009 when the financial crisis affected the financial stability of companies and discouraged the opening of new companies, support has been crucial. Grants from EU Funds, primarily the European Regional Development Fund through the measures of the Operational Program Competitiveness and Cohesion 2014-2020, enable targeted investments of start-ups. These measures work towards the growth and development of competitiveness of newly established companies through support for innovation and commercialization of innovative products and services.

The paper provides an overview of the most important financial indicators of start-ups in the Republic of Croatia that have used grants within the Call for Proposals "Innovation of start-up SMEs". These examples show the impact of grants on the financial stability of start-ups, which is crucial given that these companies are most struggling with a lack of funds for operations. The presented indicators show the effectiveness of aid for investment in product innovation and commercialization in relation to the growth and development of start-ups. The presented results are a reference point for directing investments from EU Funds of the new financial period and a possible direction for the recovery of the development of small entrepreneurs in the field of innovation in the post-COVID-19 period.

Keywords: EU funds, state aid, innovation, start-ups.



ISSN 1849-6482

