ANALIZA UZROKA RAZLIČITOG STUPNJA BRZINE KONVERGENCIJE NOVIH EU ZEMALJA ČLANICA

Ramljak, Ivan

Master's thesis / Diplomski rad

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of economics Split / Sveučilište u Splitu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:302638

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

DIPLOMSKI RAD

ANALIZA UZROKA RAZLIČITOG STUPNJA BRZINE KONVERGENCIJE NOVIH EU ZEMALJA ČLANICA

Mentor:

izv. prof. dr. sc. Josip Visković

Student:

Ivan Ramljak, univ. bacc.

Split, svibanj 2020.

SADRŽAJ

1. UVOD ... 3

1.1. Problem istraživanja ... 3

1.2. Predmet istraživanja ... 5

1.3. Istraživačke hipoteze ... 5

1.4. Ciljevi istraživanja ... 7

1.5. Metode istraživanja ... 8

1.6. Doprinos istraživanja ... 8

2. KONVERGENCIJA I EKONOMSKI RAST ... 10

2.1. Osnovni koncepti konvergencije ... 10

2.2. Analiziranje stiliziranih činjenica o ekonomskoj konvergenciji u tranzicijskim zemljama ... 14

2.2.1. Početne razine dohotka i rast ... 18

2.2.2. Ostali aspekti konvergencije - pokazatelji ljudskog razvoja ... 18

3. KVALITATIVNA ANALIZA POKRETAČA GOSPODARSKOGA RASTA TRANZICIJSKIH ZEMALJA ... 21

3.1. Računovodstvo rasta ... 21

3.2. Kapital i njegova akumulacija ... 22

3.3. Tržište rada ... 24

3.4. Ukupna faktorska produktivnost ... 29

3.4.1. Ekonomska struktura ... 29

3.4.2. Ljudski kapital ... 30

3.4.3. Trgovina i konkurentnost ... 32

3.4.4. Inovacije ... 35

3.4.5. Institucije ... 37

4. EMPIRIJSKO ISTRAŽIVANJE UZROKA RAZLIČITOG STUPNJA BRZINE KONVERGENCIJE NOVIH EU ZEMALJA ČLANICA ... 47

5. ZAKLJUČAK ... 58

LITERATURA ... 60

POPIS SLIKA ... 64

POPIS GRAFIKONA ... 64

POPIS TABLICA ... 65

PRILOZI ... 66

SAŽETAK ... 70

SUMMARY ... 71

1. UVOD

1.1. Problem istraživanja

Konvergencija je definirana kao tendencija rasta siromašnih zemalja brža od bogatih zemalja (Barro i Sala-i-Martin, 1992). Europska unija se usredotočila na konvergenciju od Rimskog ugovora (1957), kada su usvojene zajedničke politike za pod nazivom "skladan ekonomski razvoj i uravnotežene ekspanzije". Pristupanjem Irske 1973. i budućim pristupanjem Grčke, Portugala i Španjolske 1981. i 1986. stvoren je Europski fond za regionalni razvoj, a glavni cilj fonda je pomoć nerazvijenim regijama da dostignu razvijene (Berend, 2016). Zemlje koje su u procesu tranzicije i žele se pridružiti Europskoj uniji moraju ispuniti kopenhaške kriterije (1993). Suština tih ekonomskih, političkih i institucionalnih kriterija jest funkcionalnost države u ulozi članice EU. Također kako bi se pridružile Europskoj ekonomskoj i monetarnoj uniji, zemlje moraju ispuniti Maastrichtške ili konvergencijske kriterije (1992). U ekonomskoj literaturi o europskim studijama fokus je obično na procesu konvergencije novih država članica (EU-13) prema starim državama članicama (EU-15), ili približavanja zemalja zapadnog Balkana prema EU-13. Te dvije skupine zemalja dijele sličnu ekonomsku povijest. EU-13 zemlje, osim Cipra i Malte, bile su komunističke zemlje i morale su proći proces tranzicije iz centralno planiranog u tržišno gospodarstvo. Članice EU-13 su završile svoj prijelaz kada su se pridružile Europskoj uniji. Osam zemalja Srednje i Istočne Europe (CEE), Cipar i Malta pridružili su se Uniji 2004. godine, a potom Bugarska i Rumunjska 2007., te Hrvatska 2013.

Konvergenciju su popularizirali Barro i Sala-i-Martin (1992). Na temelju teorija neoklasicističkog rasta, oni analiziraju da li američke savezne države konvergiraju u razdoblju 1840. - 1988. Empirijski rezultati pokazuju postojanje konvergencije, brzinom od 2% godišnje, bez obzira na vremensko razdoblje. Jelnikar i Murmayer (2006) testiraju i potvrđuju konvergenciju među zemljama u EU-25 tijekom razdoblja 1995. - 2007. EU-10 grupa se preselila bliže prosječnoj razini dohotka po stanovniku prema EU-15 tijekom promatranog vremena. El Ouardighi i Somun-Kapetanović (2007) analiziraju proces konvergencije pet Zemalja zapadnog Balkana prema EU-27 u razdoblju 1989. - 2005. Zaključuju da se nejednakost dohotka povećala i da je konvergencija BDP-a po stanovniku dosegnula godišnju stopu koja potvrđuje osnovno pravilo od 2%. Borys i sur. (2008) istražili su konvergencijski proces pet država zapadnog Balkana prema novim državama članicama Europske unije između 1993. i

2005. Rezultati pokazuju da je Ukupna faktorska produktivnost glavni pokretač konvergencije, nakon čega je uslijedilo produbljivanje kapitala, dok je rad samo neznatno doprinio ekonomskom rastu. Vojinović i dr. (2009) analizirali su i potvrdili beta konvergenciju u zemljama Srednje i Istočne Europe u razdoblju od 1992. do 2006. godine. Stopa konvergencije u analiziranom razdoblju iznosi 4,2%. Kulhánek (2012) pokazuje da se pet zemalja srednje i istočne Europe - Češka, Mađarska, Poljska, Slovačka Republika i Slovenija - približavalo EU-15 u razdoblju 1995. - 2011. sporijom brzinom od novih Država članica (EU-12).

Botrić (2013) pokazuje kako se zemlje zapadnog Balkana (uključujući Hrvatsku) ne približavaju EU-15 ili pojedinim državama članicama EU u razdoblju 1995. - 2010. Dvoroková (2014) analizira učinke globalne financijske krize na realnu konvergenciju među državama članicama EU-a te koristi analizu linearne regresije poprečnog presjeka. Rezultati pokazuju da zemlje konvergiraju u razdoblju od 2001. do 2012. godine. Tsanana i sur. (2013) istražili su odnose između balkanskih zemalja i EU-15 u razdoblju 1989. - 2009. i zaključuju da postoje razlike između balkanskih zemalja u procesu sustizanja EU-15. Jaz u prihodima u odnosu na EU-15 ostaje značajan. Dobrinsky i Halvik (2014) pružaju različite dokazne obrasce u novim državama članicama i EU u cjelini, u pretpristupnom i u razdoblju nakon pristupanja EU, općenito ukazujući na neravnomjernu ekonomsku konvergenciju unutar EU. Borsi i Metiu (2015) istražuju ekonomsku konvergenciju u EU-27 i sugeriraju da ne postoji ukupna realna konvergencija BDP-a po stanovniku. Međutim i konvergencija i regionalne veze igraju značajnu ulogu u određivanju formacije konvergencijskih klubova. Forgó i Jevčak (2015) analiziraju ekonomsku konvergenciju zemalja srednje i istočne Europe u razdoblju od 2004. do 2014. i zaključuju da su te zemlje postigle značajne rezultate stvarne konvergencije u odnosu na dvanaest država članica EU-a koje su bile dio eurozone u 2004. Međutim, globalna financijska kriza 2008. - 2009. je imala značajan negativan utjecaj na fiskalni položaj većine zemalja CEE-10.

Colak (2015) potvrđuje konvergenciju zemalja CEE-10 i SEE-8 prema EU-15 u razdoblju 1993. - 2012. Oblath i sur. (2015) analizirali su da li članice EU-26 konvergiraju (Luksemburg i Hrvatska isključeni su iz analize) između 1999. i 2013. Analiza se fokusira na deset članica Srednje i Istočne Europe (EU-10). Rezultati pokazuju da su manje razvijene države članice EU sustigle i BDP po stanovniku i opću razinu cijena do 2008., nakon čega je uslijedilo

značajno usporavanje. Bićanić i dr. (2016) pokazuju da u Jugoslaviji nije bilo beta ili sigma konvergencije, već su se s neovisnošću razvile obje vrste konvergencije. Grela i sur. (2017) uključuju u svoju analizu dvadeset i šest država članica EU u razdoblju 1997. - 2014. i zaključuju da postoji konvergencija. Međutim, postupak je brži u razdoblju od 2001. do 2008. godine, a prekinula ga je globalna financijska kriza. Alcidi i sur. (2018) pokazuju da su zemlje središnje i istočne Europe vodile proces konvergencije u EU- 28 između 2000. i 2015. Južne su regije imale slabiji učinak od prosjeka EU. Pipień i Roszkowska (2018) analiziraju proces konvergencije u istočnoj Europi i zaključuju da je skupina CEE postala relativno homogena, dok zemlje ZND-a (Zajednica nezavisnih država) nemaju slične obrasce konvergencije među njima. Žuk i sur. (2018) analizirali su izvore gospodarskog rasta u gospodarstvima unutar i izvan Europske Unije. Konvergencija je bila mnogo brža u zemljama članicama EU nego u zemljama zapadnog Balkana. Proces je bio brz prije krize, ali je nakon nje usporen.

Gledajući dosadašnja istraživanja postavlja se pitanje kako finalno i definitivno različiti faktori utječu na stupnjeve konvergencije svih navedenih zemalja koje teže konvergenciji prema razvijenim Europskim centrima te koju ulogu igra ekonomska politika u svemu tome.

1.2. Predmet istraživanja

Kao što proizlazi iz problema istraživanja, u ovome radu istraživati će se uzroci različitog stupnja brzine konvergencije, što čini i predmete ovog istraživanja. Konkretnije istraživanje će se usmjeriti ka zemljama koje se smatraju novim članicama Europske Unije u razdoblju od 2002. do 2018. godine, a aspekti koji će biti uključeni u istraživanje biti će **klasificiranje rasta**, **akumulacija kapitala**, **tržište rada** te **pogoni ukupne faktorske produktivnosti.**

1.3. Istraživačke hipoteze

Hipoteze koje će se ovim istraživanjem provjeravati su sljedeće:

H1: Države sa većom akumulacijom kapitala imaju veći stupanj konvergencije od onih s manjom akumulacijom kapitala

Unatoč akumulaciji kapitala koja je promatrana od 2000. godine, zalihe kapitala po zaposlenoj osobi i dalje su znatno ispod prosjeka EU28 u gotovo svim tranzicijskim ekonomijama. Kapitalne praznine s naprednijim gospodarstvima EU, koje često prate niža produktivnost radne snage, posebno su velike u jugoistočnoj Europi, gdje u nekim zemljama

kapitalni intenzitet po radniku predstavlja tek otprilike jednu trećinu tog iznosa u EU28. S obzirom na nisku razinu kapitala, u prosjeku se u tranzicijskim ekonomijama čini da su visoki omjeri ulaganja ključni za brzu akumulaciju kapitala i konvergenciju u naprednija gospodarstva EU.

Spence i sur. (2008), nakon što su utvrdili da gospodarstva brže rastu u dužem vremenskom razdoblju u poslijeratnom razdoblju, istaknuli su da su u razdoblju brže konvergencije svi pokazali omjer ulaganja i BDP-a iznad 25%. Ulaganja su bila u procvatu u većini tranzicijskih gospodarstava prije 2008., a u 12 njih, stope ulaganja kretale su se iznad 25% BDP-a. Investicijski bum prije krize bio je potpomognut velikim rastom potražnje i, s obzirom na ograničene domaće uštede, uvelike se financirao iz priliva kapitala. Nakon krize, omjer investicija znatno se smanjio.

H2: Države sa razvijenijim i učinkovitijim tržištem rada imaju veći stupanj konvergencije od onih s manje razvijenim i manje učinkovitijim

U promatranom razdoblju od zadnjih dvadeset godina samo su neke tranzicijske zemlje uspjele iskoristiti demografsku dividendu, tj. potaknuti potencijal gospodarskog rasta povezan s povećanjem udjela radno sposobnog stanovništva u ukupnom stanovništvu. Iako se taj udio najviše povećao u kandidatima i potencijalnim kandidatima za EU te u nekim novim državama članicama EU-a u analiziranom razdoblju, on se smanjio u baltičkim zemljama, Češkoj i Sloveniji. U skladu s tim, doprinos rada gospodarskom rastu od 2002. godine, prosječno je bio nizak u tranzicijskim ekonomijama, te u usporedbi s primjerom ostalih brzo rastućih gospodarstava u nastajanju.

Iako su temeljni demografski trendovi u cjelini bili raznoliki, sve tranzicijske zemlje iskusile su nepovoljna kretanja migracija. Prema Atoyan et al. (2016), odljev radne snage bio je posebno velik u jugoistočnoj Europi, kako u zemljama koje su se već pridružile EU (oko 11% stanovništva 1990.), tako i u zemljama izvan EU (blizu 10%), ali je bila nešto niža u srednjoj i istočnoj Europi i baltičkim zemljama (oko 5-6% stanovništva 1990.). Nepovoljni migracijski trendovi ubrzali su se nakon ulaska ovih zemalja u EU. Emigracija se najviše odnosila na mladu i kvalificiranu radnu snagu, što je zauzvrat negativno utjecalo na produktivnost i konvergenciju dohotka.

H3: Države sa bržim rastom ukupne faktorske produktivnosti imaju veći stupanj konvergencije od onih sa manjim rastom ukupne faktorske produktivnosti

Ukupna faktorska produktivnost mjeri učinkovitost s kojim se ulažu radna i kapitalna sredstva u proizvodnom procesu i ključni je pokretač održive konvergencije. Mnogo je čimbenika koji mogu utjecati na tu učinkovitost u procesu proizvodnje, a ovo će se istraživanje usredotočiti na utjecaj ekonomske strukture, ulogu ljudskog kapitala, otvorenost trgovine i vanjsku konkurentnost, inovacije te, institucionalnu kvalitetu.

Izvori podataka te preduvjeti za ispitivanje navedenih hipoteza su sljedeći:

U modelima u kojima će se testirati sve tri navedene hipoteze koristit će se podaci iz navedenih izvora: "Penn World Table v9.1", "ECB calculations", "IMF (World Economic Outlook)", "Wiiw (FDI database)", "European Comission (AMECO database)","European Comission (EIS)", "World Bank (WDI)", "United Nations", "Organisation for Economic Co-operation and Develpoment (OECD), "World Economic Forum (GCI)", "World Intelectual Property Organisation (WIPO) statistic database", "Haver Analytic" te "EBRD",

Preduvjeti za ispitivanje hipoteza su sljedeći: Dostupnost podataka za obavljanje statističke analize iz razdoblja od 2002. do 2018. godine iz prethodno navedenih izvora, uključenost kontrolnih varijabli u regresiji kao što su: rast BDP-a u EURO zoni kao eksterni čimbenik, logaritam rasta BDP-a po stanovniku u CESEE ekonomijama modificiran sa zakašnjenjem od jedne godine kao nužna varijabla za dokaz same konvergencije, pažljiva pozornost na probleme stacionarnosti, hetereskedastičnosti i kolinearnosti te korištenje programa koji je najpristupačniji za kompleksnu ekonomsku analizu što će u ovom radu biti STATA u verziji 13.3.

1.4. Ciljevi istraživanja

S teorijskog stajališta, cilj rada jest utvrditi stilizirane činjenice konvergencije te se analiziraju pokretači gospodarskog rasta iz perspektive proizvodne funkcije, tj. akumulacije rada i kapitala te ukupnog faktorskog rasta produktivnosti, te također i faktori koji bi mogli imati određeni utjecaj na ove varijable.

S empirijskog stajališta, cilj ovoga istraživanja jest na temelju kvalitativne i kvantitativne analize utvrditi čimbenike koji mogu objasniti različite stupnjeve konvergencije novih EU zemalja članica.

1.5. Metode istraživanja

U ovome istraživanju koristit će se sljedeće znanstvene metode: induktivna metoda, deduktivna metoda, metoda analize i njeni podtipovi metode analize kvantitativna analiza, kvalitativna analiza te makroekonomska analiza. Zatim, u radu će se koristiti i metoda sinteze, te konačno s obzirom na niz čimbenika koji, osim kapitala, rada i ukupnog faktora produktivnosti utječu na ekonomsku konvergenciju, neizbježna će biti uporaba metode apstrakcije, budući da se pomoću nje „odvajaju nebitni a ističu bitni elementi i osobine određenog predmeta ili pojave istraživanja.“ (Zelenika 2000, str. 332)

U teorijskom dijelu rada, s obzirom na potrebu citiranja dosadašnjih spoznaja o problemu i predmetu istraživanja, koristit će se metoda kompilacije. Istovremeno, opisivanje logike uzročnih veza između promatranih varijabli predstavlja uporabu metode deskripcije. Također, budući da će uzorci promatranih varijabli obuhvaćati protekla vremenska razdoblja, može se govoriti o uporabi povijesne metode.

U empirijskom dijelu rada koristit će se **statistička metoda**. Ocijenjeno će biti dva različita modela od kojih će oba biti **modeli fiksnih efekata,** zato što su pristupačni i prirodni izbor za skupinu zemalja. Ovi modeli kontroliraju sve vremenske karakteristike zemlje (neusklađene s individualnim karakteristikama drugih zemalja) koje bi mogle imati utjecaja i na neovisne varijable i na prediktore. Konačno, radi vizualnog prikaza povezanosti među varijablama koristit će se i **grafičko prikazivanje**.

1.6. Doprinos istraživanja

Postoje razna istraživanja koja se bave pojmom konvergencije na prostoru Europske Unije. Autori istražuju uzroke konvergencije na nacionalnim i regionalnim razinama kroz dugoročna vremenska razdoblja te njihovi rezultati pružaju smjernice za efikasnije vođenje ekonomske politike te kvalitetnu osnovu za buduća istraživanja. Također istražuju se razlozi odstupanja sjevera i juga EU-a te zbližavanja istoka i zapada, postoje istraživanja koja obuhvaćaju svako proširenje Europske unije, te članice kandidata i potencijalnih kandidata.

Također mora se uzeti u obzir da postoje različite teorijske osnove pojma konvergencija te određena istraživanja mogu imati potpuno različite zaključke s obzirom na korištenje istih podataka i osnova za rad. U svakom slučaju postoji jako puno literature za veoma kompleksan i od visokog značaja pojam ekonomske konvergencije.

Doprinos ovoga istraživanja ogleda se u činjenici da golema kompleksnost navedene tematike otvara veliki prostor za jedinstveni pristup svakom zainteresiranom autoru, budući da ne postoji jedinstven odgovor ili pravo rješenje za svakodnevno mijenjajući svijet oko nas, svako istraživanje na jedan način doprinosi sveukupnom razumijevanju navedene kompleksne problematike. Posebnost ovoga istraživanja je uključenost svih država koje se smatraju novim članicama Europske Unije u razdoblju od 2002. do 2018. godine.

2. KONVERGENCIJA I EKONOMSKI RAST

2.1. Osnovni koncepti konvergencije

U literaturi je razvijeno i korišteno nekoliko različitih koncepata ekonomske konvergencije 1) konvergencija unutar ekonomije prema konvergenciji među ekonomijama; 2) konvergencija u smislu stope rasta prema konvergenciji u pogledu razine dohotka; 3) β-konvergencija vs σ-konvergencija; 4) bezuvjetna (apsolutna) konvergencija nasuprot uvjetnoj konvergenciji; 5) globalna konvergencija prema lokalnoj ili klupskoj konvergenciji; 6) deterministička konvergencija nasuprot stohastičkoj konvergenciji, (Islam, 2003), ali koncepti β- i σ-konvergencije imaju najznačajnije implikacije na dobrobit i stoga se najčešće analiziraju. β-konvergencija podrazumijeva da zemlje s nižim prihodima teže bržem rastu od bogatijih. β-konvergencija je nužan, ali ne i dovoljan uvjet σ-konvergencije, što zauzvrat implicira da se disperzija realnih dohodaka među zemljama vremenom smanjuje. Dakle, ako se β-konvergencija održi, to znači da siromašnije zemlje rastu brže od bogatijih, iako to možda nije dovoljno za izjednačavanje razine dohotka u zemljama tijekom vremena, pa σ-konvergencija ne mora nužno uslijediti. Ideja β-konvergencije može se izvesti izravno iz okvira neoklasičnog rasta i rezultat je pretpostavke opadajućih prinosa na kapital (Solow, 1956; Swan, 1956). U tom okviru, gospodarstva oskudna kapitalom (s malim dohotkom) pokazuju veći povrat ovog faktora proizvodnje od onih koji obiluju kapitalom (visoki dohodak), što promiče brzu akumulaciju kapitala i gospodarski rast u toj skupini zemalja. Osim gore navedenih pojmova konvergencije, u literaturi se često raspravlja i o postojanju „uvjetovanosti". Uvjetna konvergencija uzima u obzir činjenicu da se institucionalni ustroj ili politike mogu razlikovati od zemlje do zemlje. Dakle, ekonomije se mogu približiti različitim stabilnim stanjima i ekonomski rast u siromašnijim ekonomijama ne može automatski biti veći nego u bogatijim. S druge strane, bezuvjetna (apsolutna) konvergencija sugerira da siromašnije zemlje rastu brže od bogatih, bez obzira na institucionalne postavke ili politiku koju provode. Drugim riječima, dok apsolutna konvergencija pretpostavlja da gospodarstva s niskim dohotkom pokazuju brži rast po glavi stanovnika od onih s visokim dohotkom (bez uvjetovanja ili bilo kakvih drugih karakteristika tih gospodarstava), glavna ideja iza uvjetne konvergencije je da što brže ekonomije rastu, imaju niže razine kapitala koje imaju u usporedbi s vlastitim postojanim stanjem, što rezultira većim prinosom na kapital (Barro i Sala-i-Martin, 2004.). Jedan od implikacija uvjetne konvergencije bi bio da će se

ekonomije sa sličnim karakteristikama (kao što su OECD ili gospodarstva srednje i istočne Europe) dugoročno konvergirati u isto stabilno stanje. Ovaj se koncept često opisuje kao "konvergencija kluba". Ako konvergencija nije proces koji se automatski događa kao što podrazumijeva koncept uvjetne konvergencije, određivanje pokretača ekonomskog rasta i uvjeti koji podržavaju rast čini se ključnim iz perspektive politike. Dok su se modeli rasta Solow (1956) i Swan (1956) fokusirali na akumulaciju kapitala kao glavnog pokretača rasta (te se tehnološki napredak tretira kao egzogeni), sljedeći val teorijske literature nastojao je endogenizirati tehnološke promjene uključivanjem ljudskog kapitala, inovacije, ulaganja u istraživanje i razvoj ili učenja kroz rad (Romer, 1986, 1987, 1990; Aghion i Howitt, 1992; Lucas, 1988). Međutim, endogeni modeli rasta također su kritizirani jer nisu objasnili temeljne odrednice rasta (Acemoglu i ostali, 2005). Na primjer, razlike u raspodjeli resursa za inovacije ili akumulaciju ljudskog kapitala mogu se objasniti razlikama u visini dohotka, ali ne daju odgovor na pitanje zašto se te politike razlikuju u pojedinim zemljama.

Istraživanja su se u 1990-ima počela fokusirati na institucije kao temeljno objašnjenje rasta, te razlika u prihodima među zemljama i konvergencijama. Institucije se shvaćaju kao "pravila igre u društvu" (Nort, 1990.), koja oblikuju poticaje ekonomskih aktera u smislu ulaganja u fizički i ljudski kapital ili razvoja novih tehnologija (Acemoglu i sur., 2005). Institucije mogu uključivati široku paletu pravila igre, formalnih i neformalnih, kao što su imovinska prava, provođenje ugovora, učinkovitost pravosudnog sustava, kontrola korupcije, kvaliteta regulacije i upravljanja, upravljanje sukobima ili politička stabilnost (Rodrik, 2000). U novije vrijeme, povezan s fokusom na ulogu zdravih institucija, pojavljuje se i novi koncept održive gospodarske konvergencije, koji se može promatrati kao proces u kojem se dohodovni nivo gospodarstva s nižim dohotkom prilagođava, na održivoj osnovi, ekonomijama s višim dohotkom. Da bi stvarna konvergencija bila održiva, proširenje ukupne potražnje mora biti u skladu s dugoročnim potencijalnim rastom proizvodnje. Veći rast koji, primjerice, proizlazi iz financijskog procvata, može se pokazati neodrživim ako ga ne prati veći potencijalni rast. Kako bi bila održiva, stvarnu konvergenciju trebaju poduprijeti zdrave politike i institucije. U tom pogledu, nedavno se pokazalo da je institucionalna kvaliteta važna objasnjavajuća varijabla za razlike u rastu između zemalja diljem EU-a i dugoročni rast europskih gospodarstava (Masuch i sur., 2016). Još jedan istaknuti koncept u literaturi fokusiran je na geografske prednosti i aglomeracijske učinke. Prema tim konceptima, zemljopisni položaj može stvoriti povoljne uvjete

za rast i produktivnost zbog mogućih komplementarnosti i prelijevanja između poduzeća u klasterima, što bi moglo rezultirati ekonomijom razmjera u proizvodnji i privući nove tvrtke. Istovremeno, zemljopisni položaj utječe na troškove prijevoza, dok klima može utjecati na produktivnost (npr. poljoprivreda) ili neizravno preko zdravlja i ljudskog kapitala stanovništva. Jedna od važnih implikacija je da se učinci aglomeracije mogu samo i dalje pojačati, što bi moglo objasniti postojanost disperzije razine dohotka po regijama (Krugman (1991), Fujita i dr. (1999), Gallup i dr. (1999))). Učinci aglomeracije također pomažu objasniti zašto su neka zemljopisna područja ekonomski uspješnija od drugih, usprkos sličnim karakteristikama u smislu npr. institucionalne kvalitete.

Iako se uvjetna konvergencija čini vrlo privlačnom iz teorijske perspektive, apsolutna konvergencija ima osobito značajne implikacije na prosperitet i blagostanje, pa se ovaj rad iz teorijskih razloga većinom usredotočuje na taj koncept. Drugim riječima, rad želi odgovoriti te definirati utjecaj tri različita faktora na brzinu konvergencije a to su: Akumulacija kapitala, Tršište rada te Ukupna Faktorska Produktivnost. Analizirajući trendove BDP-a po glavi stanovnika od 1960-ih u svim gospodarstvima, ukazuje se na samo nekoliko slučajeva održive konvergencije od niskog / srednjeg do visokog dohotka. Zemlje koje su se uspjele pridružiti grupi najbogatijih ekonomija su Hong Kong, Irska, Japan, Južna Koreja, Singapur i Tajvan. Međutim, mnoge zemlje ne samo da se nisu uspjele približiti, već su se razišle iz skupine najbogatijih zemalja jer su postale siromašne nakon što su imale srednji dohodak. U isto vrijeme, mnoge su siromašne zemlje uspjele doći do srednjeg dohotka, ali nisu uspjele nastaviti prelaziti na visoke prihode, što je potaknulo raspravu o „zamci sa srednjim dohotkom“. Prema hipotezi o zamkama, sa postignutim srednjim dohotkom, gospodarstvima slijede vremena nižeg rasta BDP-a, što ih sprečava u postizanju visoke razine prihoda (Eichengreen i sur., 2011, 2013). Ovi su autori otkrili da je usporavanje gospodarskog rasta često povezano, s nepovoljnim demografskim situacijama i visokim udjelima ulaganja, pri čemu potonji sugeriraju preveliku ovisnost rasta BDP-a od akumulacije kapitala u ranoj fazi razdoblja nadoknade. Zamka sa srednjim dohotkom obično se objašnjava opažanjem da početne prednosti nadolazećeg gospodarstva mogu nestati nakon postizanja određene razine razvoja. Konkretnije, u ranoj fazi razvoja siromašne zemlje mogu relativno lako postići visoki rast BDP-a zbog niskih troškova rada (dakle biti visoko konkurentne na svjetskim tržištima kada proizvode radno intenzivnu robu), preraspodjelom radne snage iz sektora niže u veće produktivnosti (npr. od poljoprivrede do proizvodnje) i uvoza

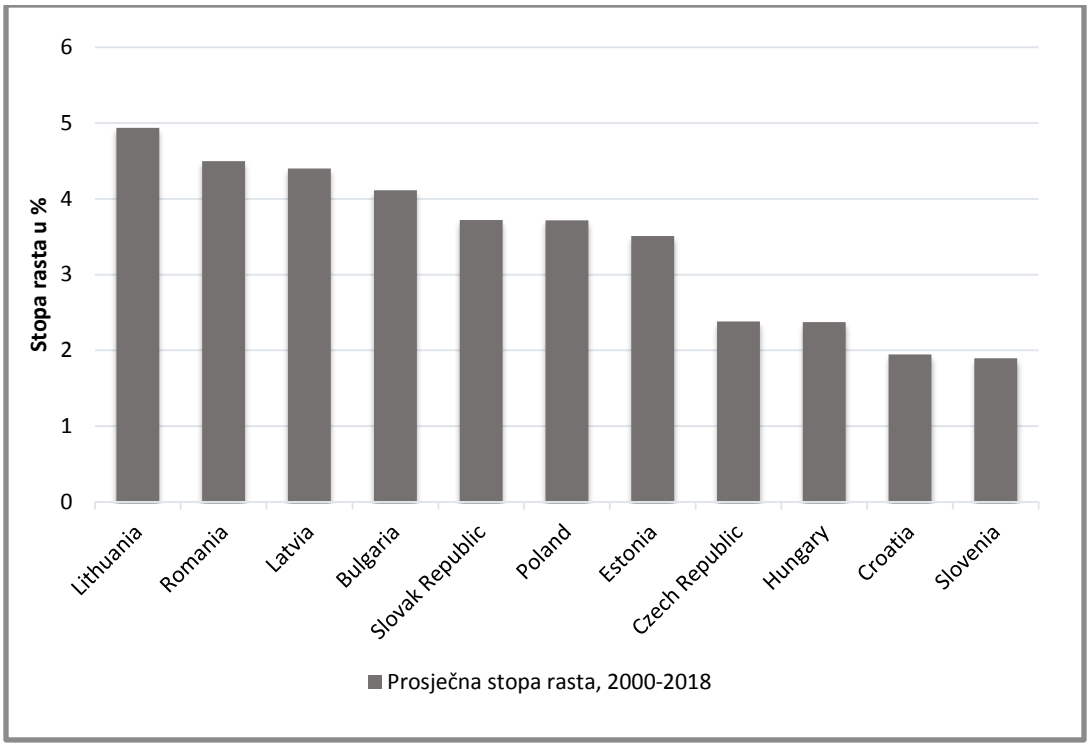
naprednih tehnologija. Međutim, nakon što se povećavaju plaće na međunarodnim razinama i na taj način smanji vanjska konkurentnost, sama sektorska preraspodjela radne snage je u velikoj mjeri dovršena te daljnja produktivnost i ekonomski rast zahtijevaju pomak s radno intenzivne proizvodnje prema inovativnijoj i tehnološki naprednijoj proizvodnji. Taj pomak ostaje izazovan i mnoge zemlje se ne uspijevaju dalje približavati, nakon što su dostigle razinu srednjeg dohotka (Agénor i sur., 2012). Ovo je zapažanje široko potvrđeno u studijama Eichengreen i sur. (2011, 2013), koji ističu da je usporavanje gospodarskog rasta manje vjerojatno u ekonomijama sa srednjim dohotkom, gdje je ljudski kapital veći, a visokotehnološki proizvodi čine relativno velik udio izvoza, međutim mora se također uzeti u obzir da dokazi koji podržavaju hipotezu o zamci sa srednjim dohotkom su dobiveni tijekom analize velikog broja zemalja tijekom duže vremenske perspektive te su pomiješani i nije lako doći do direktnih zaključaka. Iako se samo mali broj zemalja sa srednjim dohotkom uspio pridružiti skupini s visokim dohotkom od 1960. godine, mnoge su od njih suzile udaljenost od najrazvijenijih gospodarstava.

Prilikom sužavanja uzorka na europske zemlje od 2002. godine, mogu se pronaći određeni dokazi o σ-konvergenciji (a time i β-konvergenciji). Od 2002. godine sva su gospodarstva s nižim prihodima uspjela brže povećati razinu prihoda od bogatijih. Da bi se uzeo nekakav okvirni primjer uspješne ekonomske konvergencije, zemlje na južnom Kavkazu, koje su bile najsiromašnije 2002. godine, postigle su visoke stope rasta BDP-a i na taj način suzile jaz njihovog u odnosu BDP Sjedinjenih Američkih Država, što bi se moglo koristiti kao proxy granice svjetskog dohotka. Također, sve zemlje koje spadaju u CESEE regiju (Srednja, Jugoistočna i Istočna Europa) uspjele su smanjiti udaljenost od Sjedinjenih Država. S druge strane, od 2002. godine, realni prihodi po stanovniku u nekim zapadnoeuropskim zemljama različitim putanjama kretali su se od američke razine. U tom je pogledu Italija najupečatljiviji primjer, jer se BDP po glavi stanovnika u odnosu na Sjedinjene Države smanjio sa 79% u 2000. na 64% u 2016. Razvoj u nekim zapadnoeuropskim zemljama također pokazuje da, kada se analizira duže vremensko razdoblje, konvergencija može biti prividna i neodrživa. To se odnosi na neka gospodarstva eurozone (osobito Grčku i Španjolsku) koja su prije krize doživjela snažan rast BDP-a, koji je u velikoj mjeri potaknut porastom domaće potražnje u razdoblju prekomjerne kreditne dinamike, nakon čega je uslijedila bolna prilagodba (del Hoyo i sur., 2017). Stoga, bez obzira na sustizanje koje je došlo između 2000. i 2008., te su se zemlje odvojile od granice svjetskog dohotka u razdoblju od 2000. do 2018. u cjelini.

Ovaj rad fokusira se na CESEE zemlje koje su članice EU (koje se nazivaju "novim državama članicama EU" (NMS)) i uključuju Bugarsku, Hrvatsku, Češku, Estoniju, Mađarsku, Letoniju, Litvu, Poljsku, Rumunjsku, Sloveniju i Slovačku). CESEE ekonomije imaju nekoliko zajedničkih karakteristika. Prvo, zajedničko su im naslijeđe socijalističke ekonomije koje su započele proces tranzicije do tržišnih gospodarstava devedesetih godina. Drugo, to su uglavnom (osim Poljske) mala otvorena gospodarstva s neposrednom blizinom i snažnom ekonomskom vezom s većim ekonomijama EU. Treće, sve države su članice Europske Unije.

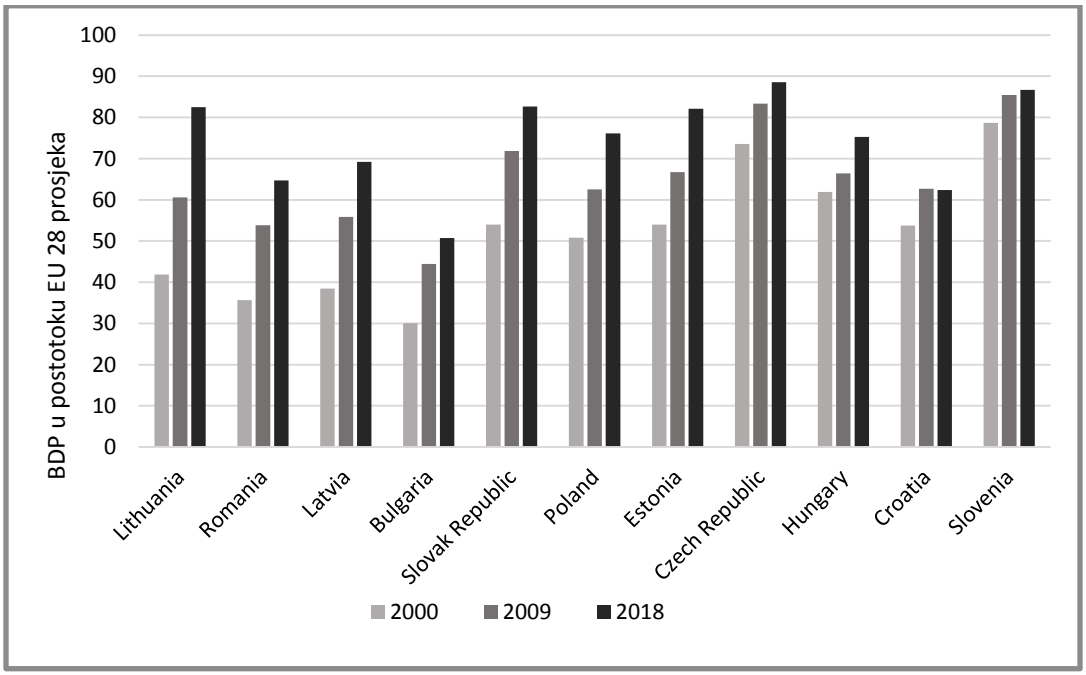
2.2. Analiziranje stiliziranih činjenica o ekonomskoj konvergenciji u tranzicijskim zemljama

U svim navedenim ekonomijama, realni BDP po stanovniku u PPP i u apsolutnom iznosu i mjereno kao udio prosjeka EU28 poboljšao se u razdoblju 2002-18. Rast BDP-a bio je posebno snažan uoči financijske krize 2008-09., dosežući stope rasta iznad 5% u nekim novim državama članicama EU-a i u najsiromašnijim ekonomijama zapadnog Balkana. Snažna ekonomska ekspanzija pridonijela je ubrzanom sustizanju naprednijih gospodarstava EU-a, međutim od 2009. godine, gospodarski rast usporio je u svim zemljama regije. Kao rezultat toga, tempo konvergencije prema prosjeku EU28 postao je sporiji nego prije krize, iako su neke zemlje, poput baltičkih zemalja i Poljske, uspjele nastaviti sustizati relativno brzim tempom i nakon 2010. godine. Korištenje pariteta kupovne moći (PPP) eliminira učinak razlike u razini cijena između zemalja i na taj način omogućava preciznije mjerenje blagostanja koje je usporedivo u svim zemljama. Zbog masovne emigracije u analiziranom razdoblju (i rezultirajući visokim priljevom inozemnih doznaka), kao i izravnim stranim ulaganjima (i rezultirajućim odljevom dohotka), BND (Bruto nacionalni dohodak) se također može smatrati mjerom ekonomskog blagostanja u analizi konvergencije. Međutim, za sva analizirana gospodarstva, stope rasta BDP-a po glavi stanovnika i BND-a po stanovniku bile su uglavnom slične u analiziranom razdoblju. Stoga se rad usredotočuje na mjeru BDP-a zbog veće dostupnosti podataka i činjenice da se ta mjera najčešće koristi u literaturi.



Grafikon 1: Prosječna stopa rasta realnog BDP-a po stanovniku (PPP) u razdoblju 2002.-2018.

Izvor: Svjetska banka i Europska centralna banka



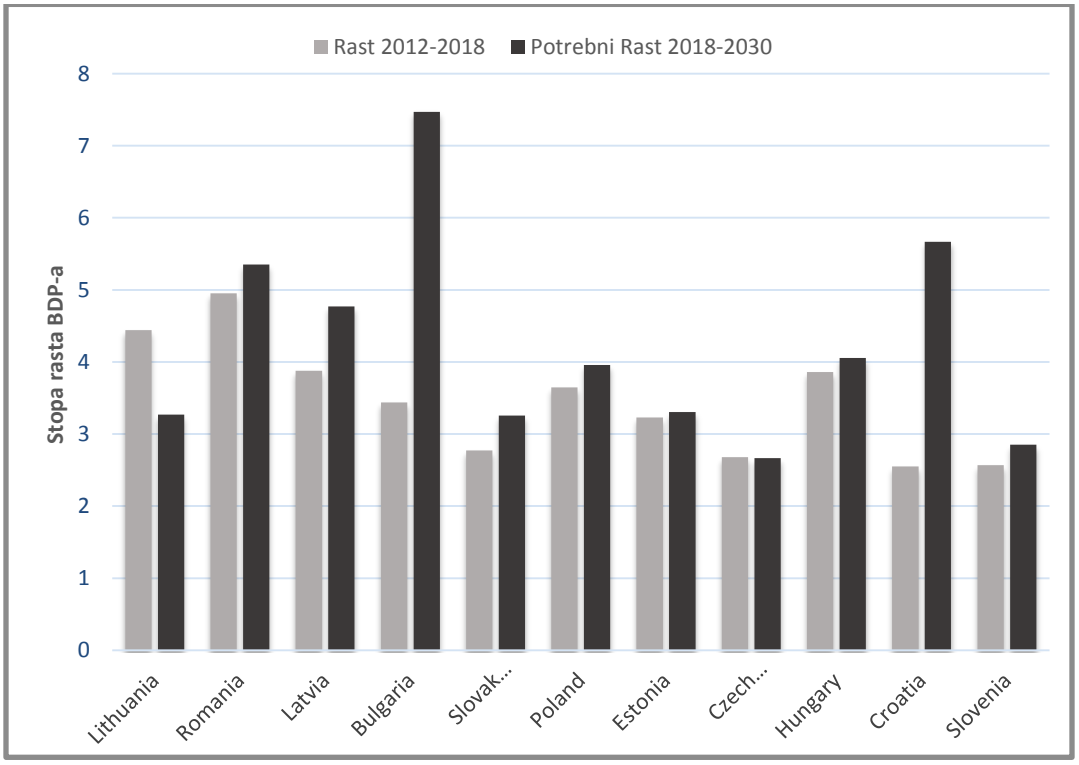
Grafikon 2: Realni BDP po stanovniku (PPP) u 2000, 2009 i 2018 godini

Izvor: Svjetska banka i Europska centralna banka

Bez obzira na ove opće osobine, relativno povećanje BDP-a po glavi stanovnika, u usporedbi s prosjekom EU, ukazuje na heterogena kretanja u skupini analiziranih zemalja. Ponajprije, usprkos visokom gospodarskom rastu, proces suočavanja dok su države još bile kandidati i potencijalni kandidati za EU u njihovim razdobljima pristupanja bio je različit od države do države, te je vrlo bitno uzeti u obzir rat na području bivše Jugoslavije devedesetih koji je destruktivno utjecao na gospodarstva u regiji i zaustavio ekonomsku tranziciju u mnogim od njih do sljedećeg desetljeća iako neke od njih nisu bile direktno u samom sukobu (Bugarska i Rumunjska). Događanja su također bila raznolika unutar zemalja CESEE-a koje su države članice EU-a u drugom sagledanom razdoblju nakon pristupanja. Neke od njih (baltičke države, Bugarska, Poljska, Rumunjska i Slovačka) doživjele su posebno brzu konvergenciju u analiziranom razdoblju. BDP po glavi stanovnika u Hrvatskoj i Sloveniji odstupio je od prosjeka EU-a nakon 2008., iako je taj negativni trend obrnut u novijim godinama. S obzirom na ta raznolika kretanja, čini se da, iako je u nekim zemljama CESEE hipoteza o zamki sa srednjim dohotkom mogla biti odbačena (barem imajući u vidu dosadašnje iskustvo), u drugima su znakovi usporavanja konvergencije nakon postizanja određene razine gospodarskog razvoja vidljivi, te se može dogoditi na različitim razinama razvoja. Zemlje CESEE-a koje su zabilježile usporavanje konvergencije (Slovenija, Mađarska i Hrvatska) od 2005. godine često su već klasificirane kao zemlje s visokim dohotkom (prema klasifikaciji Svjetske banke, Slovenija i Mađarska su zemlje s visokim dohotkom od 2016. godine, dok je Hrvatska bila zemlja s višim i srednjim dohotkom u 2016. nakon što je klasificirana kao zemlja s visokim dohotkom 2015.). Faktori koji bi mogli spriječiti daljnju konvergenciju mogli bi u najvećoj mjeri biti isti za zemlje klasificirane kao srednje dohodovne i onima koje već pripadaju skupini s visokim dohotkom, ali još uvijek imaju nedovoljno prostora da se uhvati u koštac s najnaprednijim ekonomijama. Osim toga, sve klasifikacije dohotka i granica između njih u velikoj su mjeri proizvoljne.

Kao rezultat toga, neke nove države članice EU (poput Češke i Slovenije) rano su dosegle BDP po stanovniku iznad 80% prosjeka EU28. U ostalim novim državama članicama, kao što su Poljska, Slovačka, Litva ili Estonija, unatoč brzom rastu i konvergenciji tijekom razdoblja od 2000. do 2018., BDP po stanovniku i dalje ostaje oko 20-30% niži od prosjeka EU28, no ako bi te zemlje održale stope rasta BDP-a promatrane posljednjih godina, one bi se relativno brzo (prije 2030. godine) približile prosjeku EU28. Istovremeno, za mnoge druge države članice EU iz regije konvergencija sa prosjekom EU28 u narednih 15-20 godina bila bi nemoguća bez

značajnog ubrzanja rasta BDP-a. Ovi mehanički izračuni pretvaraju da je rast BDP-a u zemljama EU-a i CESEE-a ostao na prosječnoj razini od 2010. do 2018. Također, potrebno je uzeti u obzir vjerojatno nepredvidiv gospodarski rast nakon što zemlje postignu višu razinu BDP-a po glavi stanovnika, kao i druge izazove za daljnji gospodarski rast i konvergenciju, ali također treba uzeti i obzir mogući potencijalni utjecaj izlaska Velike Britanije iz EU-a, što će statistički smanjiti prosječne prihode u EU.



Grafikon 3: Potrebni potencijalni rast BDP-a s ciljem postizanja prosjeka svih EU članica do 2030-te godine

Izvor: Svjetska banka i Europska centralna banka

Budući da želimo dobiti jednu širu sliku vezanu za potencijalni rast BDP-a, bilo bi dobro da bacimo jedan kratak osvrt što se tiče pitanja kandidata za EU i potencijalnih kandidata s ciljem smještanja rasta u jednu širu perspektivu. U 2018. su sva gospodarstva zapadnog Balkana imala nivo prihoda koji je iznosio manje od 50% prosjeka EU28; s najnižim BDP-om po glavi stanovnika u PPP-u mjerenim na Kosovu (27%), a najvišim u Crnoj Gori (44%). Općenito, većina kandidata i potencijalnih kandidata za EU još uvijek je daleko od postizanja razine konvergencije dohotka do prosjeka EU, tipičnog za vrijeme pristupanja za zemlje EU u uzorku

koji je analiziran (koji je u većini slučajeva iznosio oko 50-60% prosjeka BDP po glavi stanovnika u EU). Da bi do 2030. godine dosegla razinu od 50% prosječnog BDP-a po stanovniku u EU28, većina zemalja kandidatkinja za EU i potencijalnih kandidata trebalo bi pokazati astronomsko veći rast BDP-a u odnosu na prethodne godine. Samo se u Crnoj Gori čini da je izazov nešto manji, budući da je do sada zabilježen rast BDP-a već blizu onog koji bi omogućio dostizanje takve razine do 2030. godine.

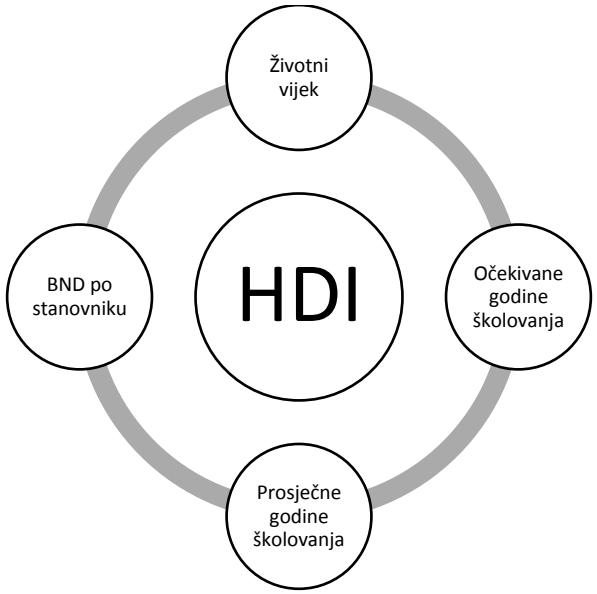
2.2.1. Početne razine dohotka i rast

Siromašnije države CESEE-a zabilježile su snažniji ekonomski rast između 2000. i 2018., što je u skladu s hipotezom o bezuvjetnoj β konvergenciji. Međutim, povezanost između početnih nivoa dohotka i prosječnog godišnjeg rasta čini se snažnijom (i negativnom) u novim državama članicama EU koje su se pridružile eurozoni nego u ostalim državama, te nadalje, analiza zemalja novih država članica izvan euro-područja sa sličnim razinama dohotka u 2000. otkriva da je skupina imala znatno višu prosječnu godišnju stopu rasta nakon pristupanja. Ova dva zapažanja mogu ukazivati na pozitivnu ulogu koju je pristupanje EU-u i eurozoni igralo u konvergenciji CESEE ekonomija. Ono što je također upečatljivo je da se, dok se disperzija dohotka unutar grupe novih država članica EU unutar i izvan eurozone smanjila od 2000. godine, ove dvije skupine se međusobno razlikuju. Takav razvoj podupire hipotezu o „konvergenciji kluba“ u uzorku koji je analiziran i sugerira da su države članice CESEE-a do sada postigle različite stupnjeve razvijenosti ovisno o ekonomskoj integraciji.

2.2.2. Ostali aspekti konvergencije - pokazatelji ljudskog razvoja

Kada se analizira konvergencija dohotka, potrebno je imati na umu ograničenja BDP-a kao mjere dobrobiti, o kojima se uvelike raspravlja u literaturi (Stiglitz i sur., 2008). BDP je mjera gospodarske aktivnosti, dok se razvoj zemlje često smatra smanjivanjem nejednakosti u dohotku, otvaranjem novih radnih mjesta i poboljšanim pristupom zdravstvenoj zaštiti i obrazovanju. Dakle, samo promatranje rasta BDP-a neće u potpunosti obuhvatiti ovaj višedimenzionalni aspekt. Nadalje, u nizu radova koji su istraživali povezanost gospodarskog rasta i ljudskog razvoja utvrđeno je da ljudski razvoj nije samo krajnji proizvod procesa razvoja, već i sredstvo generiranja budućeg gospodarskog rasta (vidi npr. Ranis i sur., 2000 ; Boozer i

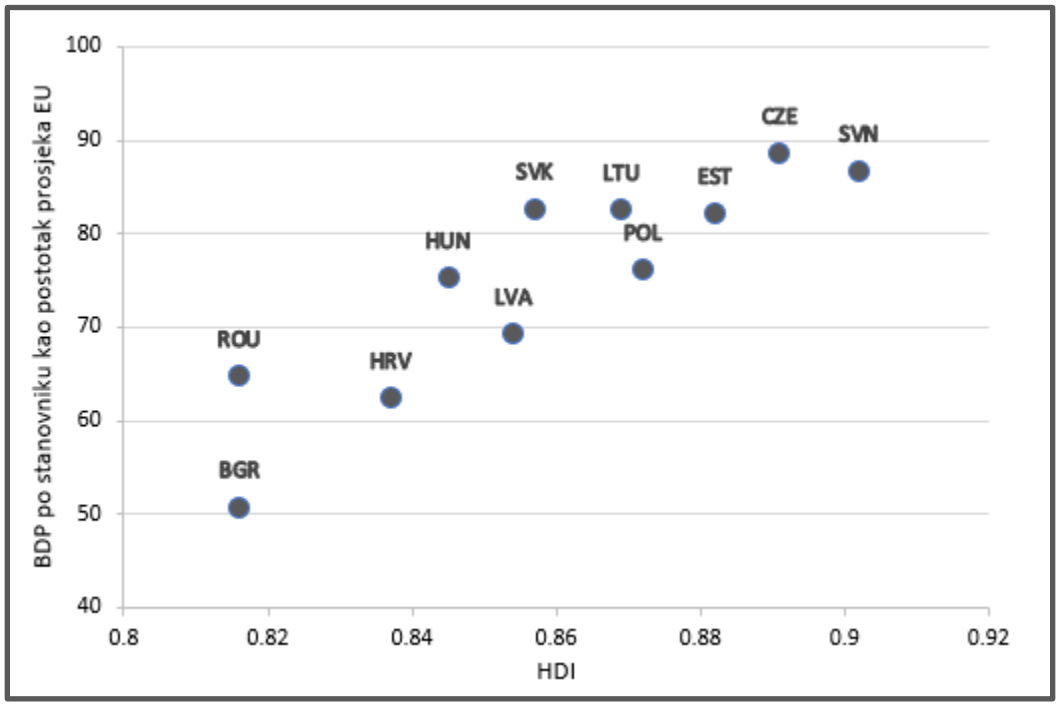
sur., 2003). Human Development Index – HDI (Indeks ljudskog razvoja kojeg su razvili Ujedinjeni narodi) sastoji se od četiri komponente, i to su: (i) očekivani životni vijek po rođenju, (ii) očekivane godine školovanja, (iii) srednje godine školovanja i (iv) bruto nacionalni dohodak, te je on geometrijska sredina normaliziranih indeksa za svaku od tih dimenzija. Iako se metodologija za izračunavanje HDI-a suočila s kritikom (posebno zbog izbora dimenzija i metoda združivanja, za dodatne pojedinosti pogledajte npr. Kovačević (2011)), tvrdeći da jedan indeks ne može uhvatiti karakter mnoštva pokazatelja ili da HDI prikazuje previše pojednostavljeni pogled na ljudski razvoj oslanjajući se na samo nekoliko pokazatelja, HDI i dalje ostaje koristan pokazatelj koji omogućava širi fokus pokazatelja nego što prikazuje sami ekonomski rast te se može koristiti u komparativnom aspektu među CESEE zemljama.



Slika 1: Sastavnice HDI-a

Pozitivan odnos između razine dohotka po stanovniku i indeksa ljudskog razvoja (HDI) postoji među zemljama CESEE-a. U promatranom razdoblju, konvergenciju prihoda CESEE ekonomija pratio je značajan napredak u smanjenju siromaštva (EBRD, 2018), povećavajući pristup obrazovanja ili produljenja očekivanog trajanja života. Shodno tome, većina naprednih država članica Europske zajednice CESEE-a već imaju ocjene više nego neke druge države članice EU. Također, postoji disperzija u akumulaciji bogatstva unutar stanovništva, ali nejednakost (mjerena Gini koeficijentom) nije veća nego na ostalim tržištima u nastajanju.

Sveukupno, kad se prilagode nejednakostima unutar zemlje (koje se odnose na očekivani životni vijek, obrazovanje i prihode), nove države članice EU-a postižu viši nivo nego što bi to podrazumijevale njihove razine dohotka, što je posljedica kako relativno manjih nejednakosti u regiji, tako i većeg ljudskog kapitala (pomnoženo sa srednjim godinama školovanja). S druge strane, zemlje zapadnog Balkana često pokazuju niže HDI indekse nego što bi sugerirale njihove razine prihoda.



Grafikon 4: HDI i BDP u CESEE državama u 2018. godini

Izvor: Haver Analytics, razvojni program Ujedinjenih naroda, izračuni osoblja Svjetske banke i ECB

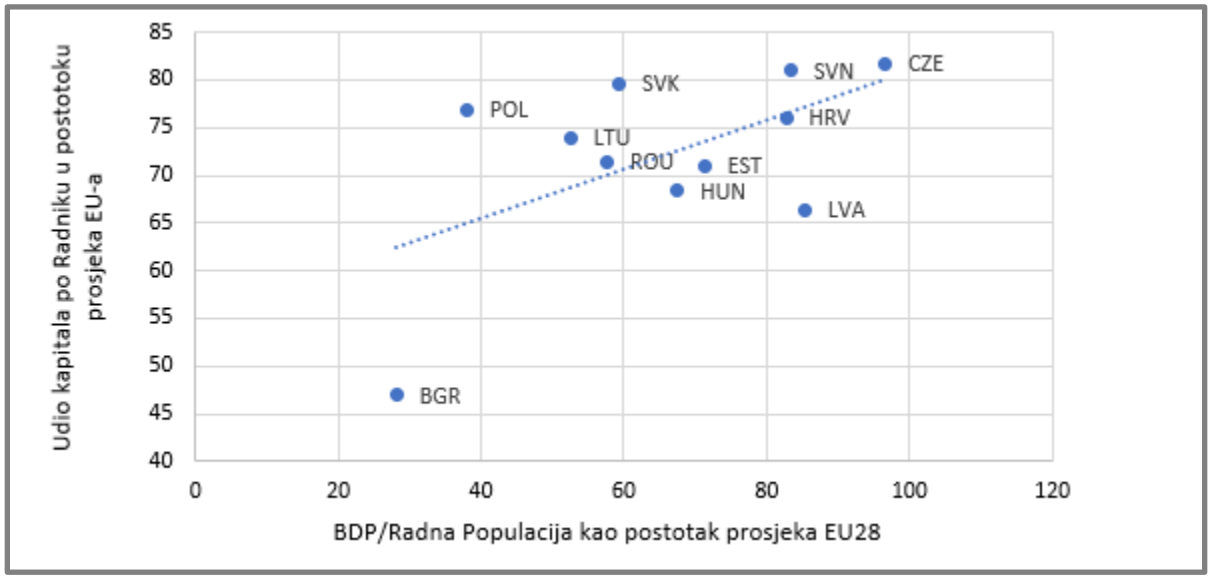
3. KVALITATIVNA ANALIZA POKRETAČA GOSPODARSKOGA RASTA TRANZICIJSKIH ZEMALJA

3.1. Računovodstvo rasta

Računovodstvena analiza rasta gospodarstava CESEE pokazuje da se gospodarski rast od 2002. godine u velikoj mjeri temelji na rastućoj ukupnoj faktorskoj produktivnosti i akumulaciji kapitala. S druge strane, zemlje CESEE doživjele su miješana demografska kretanja, što je rezultiralo da je doprinos rastu u prosjeku blizu nule. Stoga se ovaj obrazac rasta donekle razlikovao od onog u mnogim drugim konvergirajućim ekonomijama koji su često analizirani u literaturi, gdje je rast često bio zasnovan na kapitalu i akumulaciji radne snage. Računovodstvo rasta omogućava kvantificiranje doprinosa akumulacije kapitala i rada ukupnom ekonomskom rastu. Dio ekonomskog rasta koji se ne može objasniti akumulacijom tih faktora proizvodnje obično se pripisuje ukupnom rastu produktivnosti faktora (međutim, neobjašnjivi dio mogao bi objasniti npr. pogrešku mjerenja ili akumulaciju ljudskog kapitala). Računovodstveni proračuni rasta za CESEE zemlje u ovom radu temelje se na Penn World Tables bazi (verzija 9.1). Relativna snaga pokretača gospodarskog rasta CESEE-a bila je različita u radom obuhvaćenim zemljama i razdobljima. Prije krize (tj. između 2002. i 2008.), relativna snaga pokretača rasta bila je uglavnom slična u cijeloj regiji, s posebno snažnim doprinosom rasta TFP-a i akumulacije kapitala. Iako je akumulacija radne snage u prosjeku podržavala i ekonomski rast, njezin je doprinos i dalje ostao malen u svim skupinama gospodarstava. Nakon krize, gospodarski rast u zemljama CESEE-a usporava i uglavnom je bio povezan sa sporijim rastom TFP-a. Kao rezultat toga, gospodarski rast u regiji postao je više ovisan o akumulaciji kapitala. To je posebno vidljivo na zemljama koje su danas potencijalni kandidati EU-a, gdje je akumulacija kapitala u praksi postala jedini pokretač gospodarskog rasta. U novim državama članicama EU izvan europodručja, doprinos akumulacije kapitala također je postao glavni pokretač rasta, iako je rast TFP-a također objasnio značajan dio ukupnog gospodarskog rasta. Suprotno tome, u zemljama eurozone u regiji, rast TFP-a ostao je glavni pogon. Istodobno su se demografski izazovi pojavili na području čitavog kontinenta.

3.2. Kapital i njegova akumulacija

Unatoč akumulaciji kapitala koja je promatrana od 2002. godine, zalihe kapitala po zaposlenoj osobi ostaju znatno ispod prosjeka EU28 u gotovo svim ekonomijama CESEE-a. Nedostatak kapitala u usporedbi s naprednijim gospodarstvima EU, kojeg često prati niža produktivnost radne snage, posebno je istaknuta u jugoistočnoj Europi, gdje u nekim zemljama članicama i zemljama kandidatkinjama kapital po radniku po iznosu je daleko manji u odnosu na prosjek EU 28. S obzirom na nisku razinu kapitala, u prosjeku se u CESEE ekonomijama čini da su visoki omjeri ulaganja neophodni za brzu akumulaciju kapitala i konvergenciju u naprednija gospodarstva EU.



Grafikon 5: Kapital po radniku i produktivnost rada u 2018. godini u CESEE zemljama članicama EU-a

Izvor: Penn World Table verzija 9.1 i MMF (World Economic Outlook).

Spence i sur. (2008), nakon što su utvrdili da gospodarstva brzo rastu kroz duže vremensko razdoblje u poslijeratnom razdoblju, istaknuli su da su u razdoblju brže konvergencije svi subjekti pokazali omjer ulaganja i BDP-a iznad 25%. Ulaganja su bila u procvatu u većini gospodarstava CESEE-a i prije 2008., a u osam od njih, stope ulaganja kretale su se iznad 25% BDP-a. Međutim, domaće stope štednje nisu bile dovoljne za financiranje investicijskog procvata i velike razlike u štednji (tj. razlike između omjera ulaganja i domaće štednje) činile su zajedničku karakteristiku zemalja CESEE, one su bile osobito visoke u jugoistočnoj Europi,

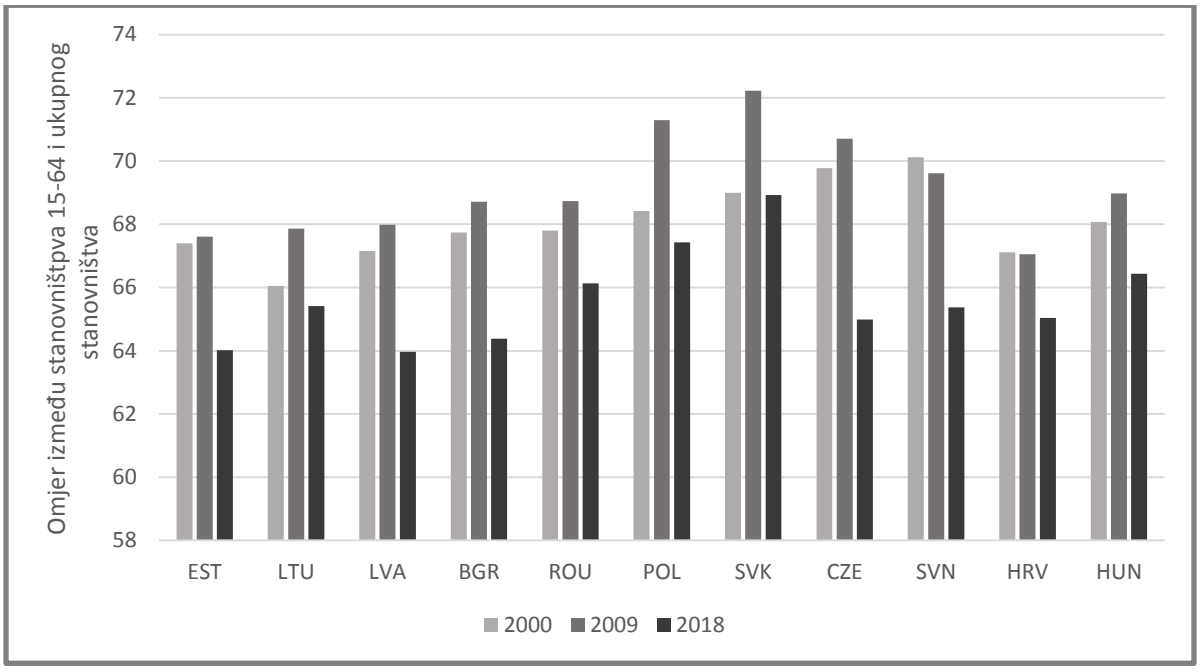
uključujući članice, trenutne kandidate za EU i potencijalne kandidate, te u baltičkim zemljama, gdje su u nekim slučajevima razlike u uštedama dosezale dvoznamenkasti broj. Investicijski bum prije krize bio je potpomognut velikim rastom potražnje i, s obzirom na ograničene domaće uštede, uvelike se financirao iz priliva kapitala. Ti priljevi kapitala uključuju, posebno, zajmove banaka i izravna strana ulaganja (FDI), te povrh toga, izravna strana ulaganja nisu samo pozitivno utjecala na akumulaciju kapitala, već su omogućila i prijenos tehnologije i znanja, podržavajući rast TFP-a (Damijan i sur., 2013). Međutim, visoki omjeri ulaganja često se odražavaju i na visoku investicijsku aktivnost u građevinskom sektoru, koju su u određenoj mjeri potaknuli „kreditni boomi" u mnogim zemljama CESEE-a prije krize, što je vjerojatno imalo ograničen utjecaj na produktivnost rada i dugoročne perspektive rasta. Na primjer, Sala-i Martin (1997.) utvrdili su da ulaganja u opremu ne utječu na rast BDP-a ako se kontrolira nivo ukupnog ulaganja. Istovremeno, autori su pronašli snažnu vezu između ulaganja u opremu i rasta, potvrđujući tako prethodne rezultate koje su dobili DeLong i Summers (1991).

Nadalje, povećavajući financijsko posredovanje u načelu se može, podržavati gospodarski rast, posebno u zemljama u kojima je financijsko posredovanje i dalje relativno nisko, te je ubrzano nagomilavanje duga prije krize u nekim zemljama CESEE-a (osobito u onim koje koriste euro), praćeno razdvajanjem privatnog sektora, što je zauzvrat ostao zastoj rasta BDP-a nakon krize. Financijska dubina, međutim, i dalje je u prosjeku niska u cijeloj regiji (kao rezultat domaćih kredita privatnom sektoru u postotku BDP-a) u usporedbi s prosjekom EU28. Iako se pozitivna uloga financijskog posredovanja u poticanju gospodarskog rasta općenito potvrđuje u literaturi (za opsežan pregled teorijskih i empirijskih studija o ovoj temi istraživao je Levine (2005)), neki radovi također ističu da je pretjerano veliki financijski sektor može rezultirati financijskom krhkošću, dok brzi rast kredita može pratiti financijska kriza (Arcand i sur., 2012). Nakon krize, udio investicija u BDP-u znatno se smanjio, te se to dogodilo uslijed sporijeg rasta BDP-a, nižeg priljeva kapitala, usporavanja građevinskih aktivnosti i nižeg rasta kredita. Sveukupno, samo pet gospodarstava CESEE uspjelo ga je zadržati iznad 25% BDP-a, istodobno, što su veće razlike u štednji bile prije krize, veće su korekcije omjera ulaganja nakon pada, a kako su omjeri ulaganja padali, oni su se pobliže usklađivali sa stopama domaće štednje. Iskustvo brzo rastućih ulaganja prije krize praćeno značajnim prilagođavanjem nakon toga, ukazuje na zaključak da iako se kapitalni tokovi ka ekonomijama koje se konvergiraju i ekonomiji oskudnim kapitalom čine ključnim za poticanje gospodarskog rasta i konvergencije, s

druge strane mogu i pogoršati nestabilnost u tim gospodarstvima, posebno ako portfeljni kapitalni tokovi ili tokovi bankarskog sektora dominiraju umjesto stabilnijih izvora financiranja kao što su izravna strana ulaganja.

3.3. Tržište rada

U razdoblju od 2000. do 2018. samo su neke zemlje CESEE-a uspjele iskoristiti demografsku dividendu, tj. potaknuti potencijal gospodarskog rasta povezan s povećanjem udjela radno sposobnog stanovništva u ukupnom stanovništvu, Iako se taj udio najviše povećao u kandidatima i potencijalnim kandidatima za EU, te u nekim novim državama članicama EU-a u analiziranom razdoblju, on se smanjio u baltičkim zemljama, Češkoj i Sloveniji. U skladu s tim, doprinos rada gospodarskom rastu od 2000. godine, prosječno je bio nizak u CESEE ekonomijama, u usporedbi s primjerom ostalih brzo rastućih gospodarstava u nastajanju.



Grafikon 6: Stanovništvo u dobi od 15 do 64 godine u omjeru ukupnog stanovništva u 2000., 2009. i 2018. godini

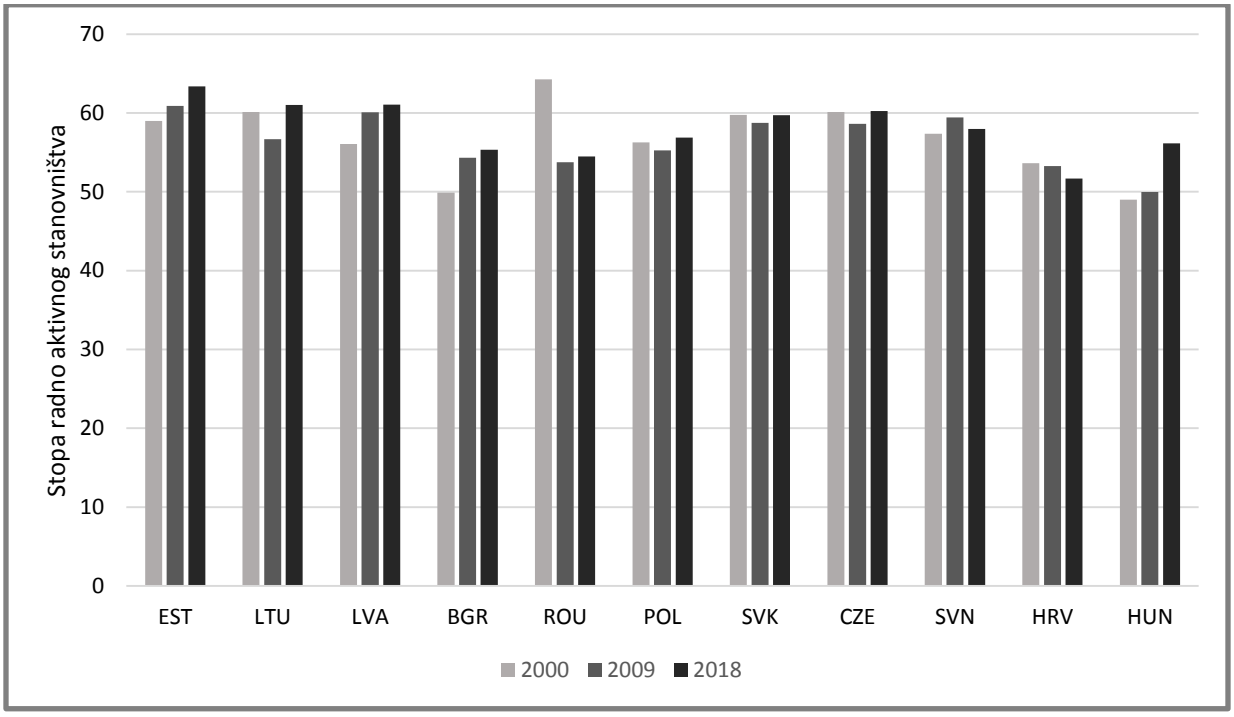
Izvor: Podaci Svjetske banke (WDI) koje je prikupila Međunarodna organizacija za rad

Iako su temeljni demografski trendovi u cjelini bili raznoliki, sve zemlje CESEE-a su se suočile s nepovoljnim migracijskim kretanjima. Prema Atoyanu (2016), odljev radne snage bio je

posebno velik u jugoistočnoj Europi, kako u zemljama koje su se već pridružile EU (oko 11% stanovništva 1990.), tako i u zemljama izvan EU (blizu 10%), ali je bila nešto niža u srednjoj i istočnoj Europi i baltičkim zemljama (oko 5-6% stanovništva 1990.). Nepovoljni migracijski trendovi ubrzali su se nakon ulaska ovih zemalja u EU. Emigracija se najviše odnosila na mladu i kvalificiranu radnu snagu, što je zauzvrat negativno utjecalo na produktivnost i konvergenciju dohotka. Gledajući unaprijed, očekuje se da će se izazovi povezani s opadanjem udjela stanovništva radne dobi povećavati zbog ubrzanja starenja stanovništva. Očekuje se da će radno sposobno stanovništvo naglo pasti u svim zemljama CESEE, a najveći pad će biti u baltičkim i jugoistočnim zemljama EU. Takav razvoj događaja može imati znatne posljedice na ekonomski rast. Ponajviše će imati izravan negativan utjecaj na gospodarski rast kroz manji unos radne snage, istovremeno, starenje stanovništva može imati i neizravne učinke na gospodarski rast kroz njegov utjecaj na ukupnu produktivnost, uštede ili razinu i strukturu javnih rashoda, premda u literaturi još uvijek ne postoji konsenzus o točnom mehanizmu putem kojeg starenje stanovništva matematički točno utječe na te varijable. Treba imati na umu i da će starenje vjerojatno potaknuti reakcije politika i ponašanja koje mogu imati nejasan utjecaj na ukupnu ekonomsku aktivnost. To može uključivati promjene u dizajnu mirovinskih sustava, politika tržišta rada, obrasca štednje ili ulaganja u ljudski ili fizički kapital. Na primjer, pod pretpostavkom smanjenja produktivnosti u skladu s godinama, starenje stanovništva može umanjiti ukupnu produktivnost. Međutim, empirijske studije o ovom mehanizmu nisu uvjerljive (vidjeti na primjer Skirbekk (2004), van Ours i Stoeldraijer (2010); Bloom i Sousa-Poza (2013)). Neki autori (Lee i Mason (2010)) navode da rastuća dugovječnost, zajedno s niskom stopom plodnosti, može povećati ulaganja u ljudski kapital i rezultirati većom produktivnošću i ekonomskim rastom. Također Bloom i sur. (2014) formuliraju hipotezu da starenje može potaknuti reakcije na ponašanje, povezane s, na primjer, sve većim sudjelovanjem žena u radu ili ulaganjem u tehnologije za uštedu rada. U isto vrijeme, dok opadajući udio radno sposobnog stanovništva, koji obično pokazuje veće stope štednje, može dovesti do niže ukupne štednje, povećani životni vijek može imati obrnuti učinak na ovu varijablu (Bloom i sur., 2007).

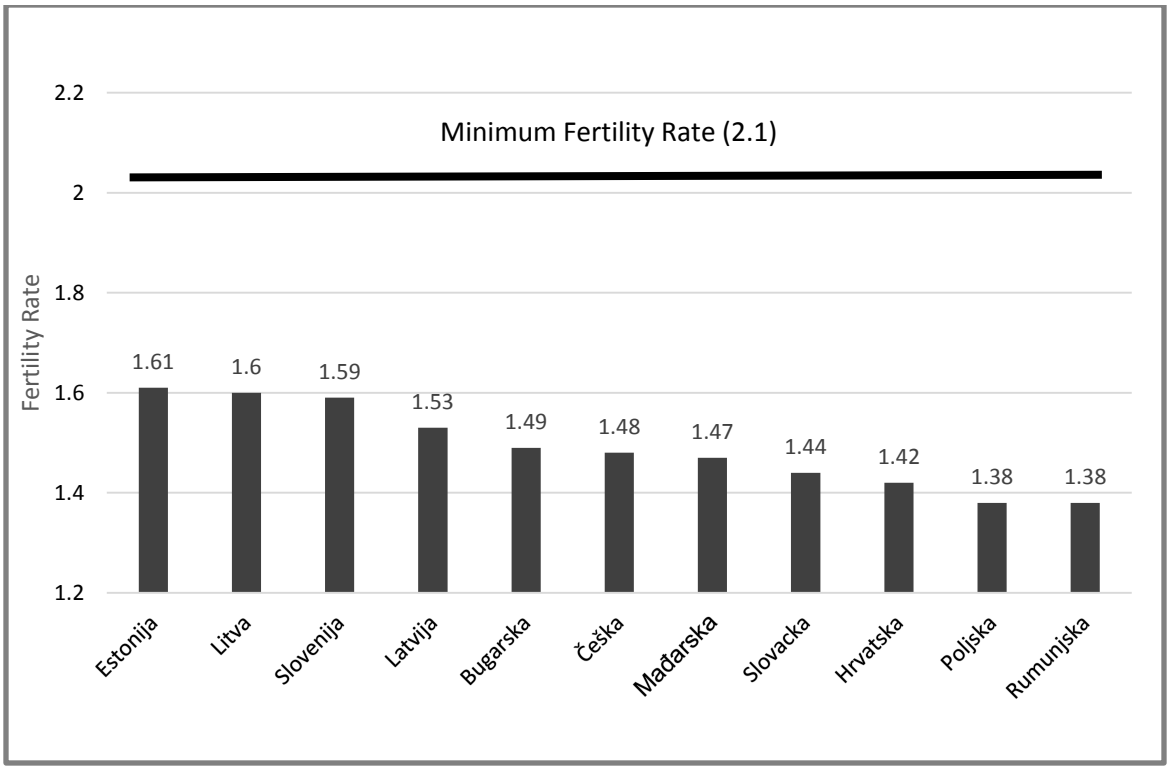
Negativne implikacije promjene strukture stanovništva na tržištu rada mogu se ublažiti povećanjem sudjelovanja u radu. Iako su stope sudjelovanja u radu država Baltika ili nekim zemljama srednje i istočne Europe već na relativno visokim razinama, još uvijek postoji značajan prostor za veću aktivnost u jugoistočnoj Europi, posebno u Republici Hrvatskoj, u kojoj je stopa

sudjelovanja u prosjeku skoro deset postotnih poena niža nego u prosjeku Europske Unije, pogotovo nakon velikih emigracijskih valova od 2013. godine nadalje. Ako se promatra dodatno povećanje zaposlenosti, ista bi mogla rezultirati boljim usklađivanjem ponude i potražnje radne snage i stoga nižom stopom nezaposlenosti, koje su u zemljama Balkana i dalje visoke. Opseg za veće sudjelovanje na tržištu rada jasno je vidljiv kada se analizira najugroženije skupine na tržištu rada. Na primjer, u 2019. godini stopa sudjelovanja u radu među mladima (u dobi između 15 i 24 godine) bila je ispod prosjeka EU-a (42,2%) u svim zemljama CESEE-a. Posebno je nizak (ispod 30%) bio u Bugarskoj i Mađarskoj. U većini zemalja CESEE-a postoji i velik prostor za povećanje sudjelovanja žena, posebno među najnovijim članicama EU (Bugarska, Rumunjska i Hrvatska). Suprotno tome, aktivnost na tržištu rada žena je relativno velika u baltičkim zemljama (također u usporedbi s prosjekom EU). Slični zaključci mogu se izvući i analizom sudjelovanja starijih kohorti na tržištu rada, što je u većini zemalja CESEE-a relativno malo.



Grafikon 7: Stopa radno aktivnog stanovništva u 2000, 2009 i 2018 godini

Izvor: Podaci Svjetske banke (WDI) koje je prikupila Međunarodna organizacija za rad

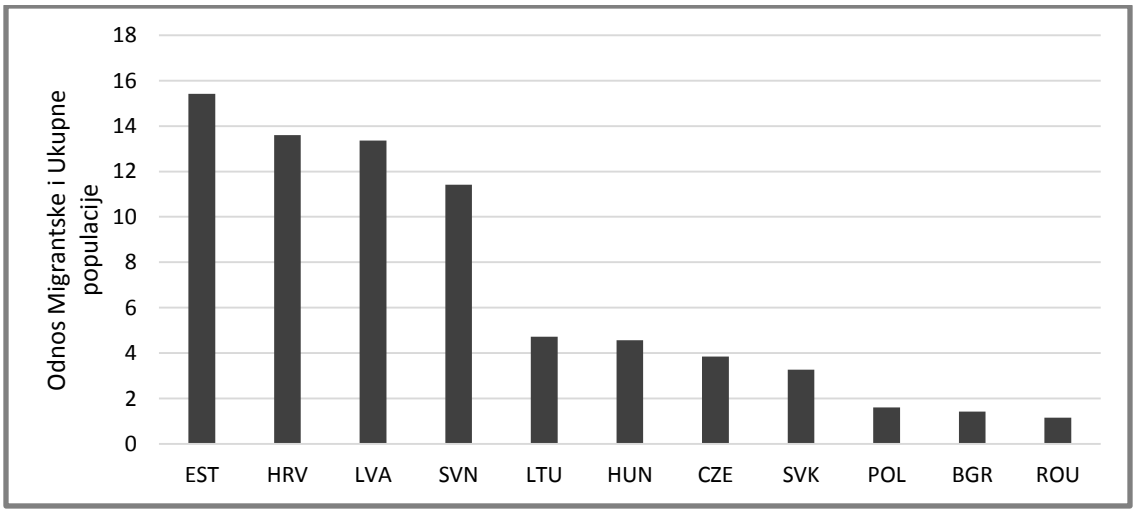


Grafikon 8: Prosječan broj djece po ženskoj osobi za razdoblje čitavog života

Izvor: Svjetska banka

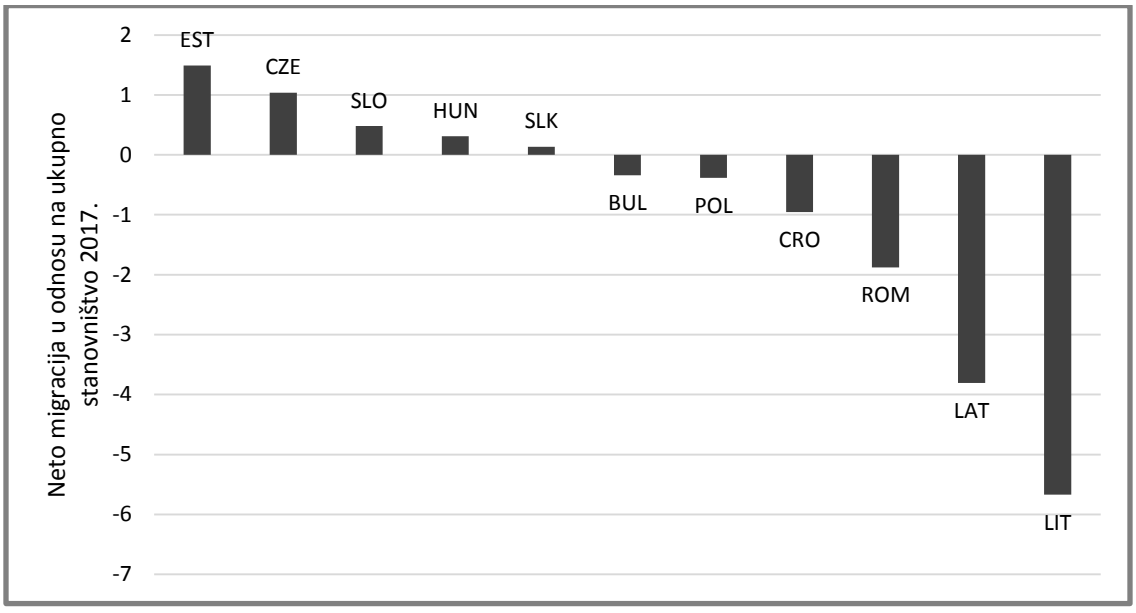
Sljedeći mogući način ublažavanja negativnog utjecaja padajućeg udjela radno sposobnog stanovništva na tržište rada je imigracija. Unatoč velikoj heterogenosti u analiziranim zemljama, u većini njih broj imigranata kao dio stanovništva i dalje je nizak (prosječno 3,3%, u usporedbi s 10,6% u EU28 u 2015.). Iako je imigracija u nekim ekonomijama CESEE-a već povećana u analiziranom razdoblju, uglavnom je bila potaknuta velikim imigracijama iz drugih manje razvijenih CESEE zemalja, koje se i same suočavaju s demografskim izazovima. Primjerice, porast broja imigranata u Sloveniji uvelike je utjecao na priljev građana Bosne i Hercegovine i Bivše jugoslavenske republike Makedonije, dok je Mađarska imala priljev stanovništva iz Rumunjske i Srbije. S druge strane, broj imigranata u baltičkim državama znatno se smanjio u promatranom razdoblju, ponajviše zbog pada broja ruskih i bjeloruskih državljana. Općenito, potencijal imigracije za ublažavanje izazova povezanih sa starenjem stanovništva do sada je iskorišten samo u ograničenom stupnju u regiji. Ipak zbog razmjera očekivane demografske promjene imigraciju bi trebalo smatrati politikom koja može ublažiti, ali ne i potpuno prevladati, negativne posljedice starenja na tržišta rada u regiji. Na primjer, 2016. godine Poljska je zabilježila neviđen priliv ukrajinskih državljana, a više od 500 000 njih dobilo

je dozvolu boravka (prema podacima Eurostata), no očekivanje je da će se stanovništvo u radnoj dobi u Poljskoj smanjiti za više od 3,1 milijuna do 2030. godine i za 8,1 milijuna do 2050. godine (u usporedbi s 2015. godinom; prognoza Svjetske banke). Nadalje, privlačenje imigranata zahtijeva ponudu ekonomske mogućnosti na tržištu rada, koje su obično ograničene u zemljama koje i dalje trpe relativno visoku nezaposlenost, posebno na Balkanu.



Grafikon 9: Udio migranata u ukupnom stanovništvu

Izvor: Penn World Tables 9.1 i Europska komisija



Grafikon 10: Neto stanje migrantskog kretanja u odnosu na ukupno stanovništvo u 2018.

Izvor: Penn World Tables 9.1

3.4. Ukupna faktorska produktivnost

U ovom su poglavlju analizirani čimbenici koji bi mogli imati opipljiv utjecaj na ukupnu faktorsku produktivnost u državama CESEE-a. Ukupna faktorska produktivnost mjeri učinkovitost s kojim se ulažu radna i kapitalna sredstva u proizvodnom procesu i ključni je pokretač održive konvergencije. Mnogo je čimbenika koji mogu utjecati na tu učinkovitost proizvodnog procesa, a ovaj će se pododjeljak usredotočiti na utjecaj ekonomske strukture, ulogu ljudskog kapitala, otvorenost trgovine i vanjsku konkurentnost, inovacije te, na kraju, temeljnu ulogu po institucionalnoj kvaliteti.

3.4.1. Ekonomska struktura

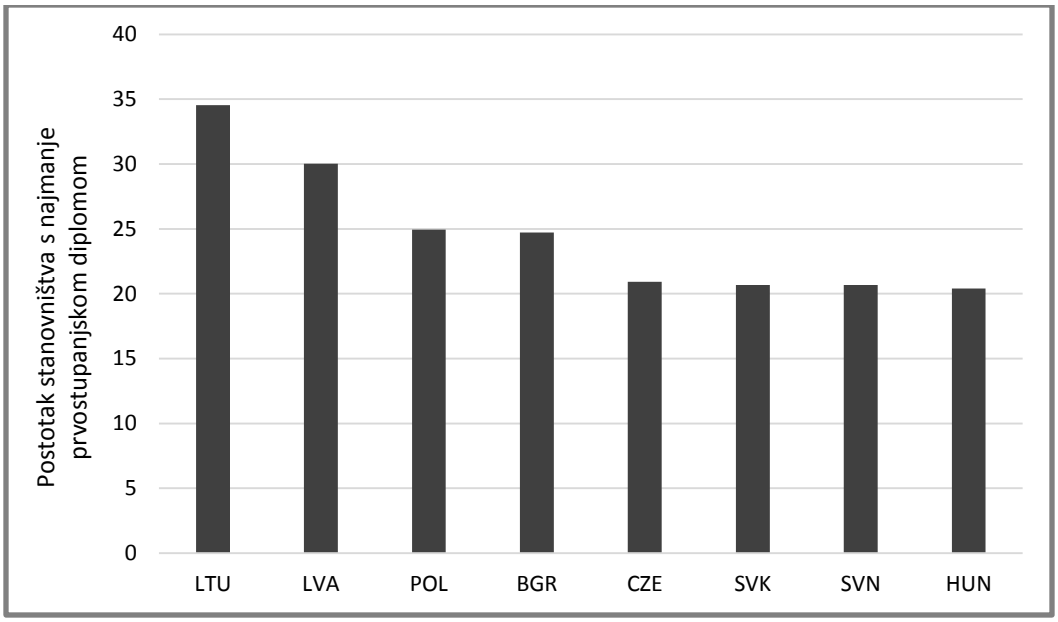
Zbog različitih razina produktivnosti u svim sektorima gospodarstva, struktura gospodarstva ima izravan utjecaj na ukupnu produktivnost i gospodarski rast. Važno je naglasiti da je produktivnost u poljoprivredi obično niža nego u uslugama i industriji te da visok udio ukupne dodane vrijednosti u poljoprivredi može negativno utjecati na razinu produktivnosti u gospodarstvu. Istodobno, preraspodjela radne snage iz poljoprivrede u industriju i usluge podržava produktivnost i gospodarski rast. Stilizirani obrazac je da, kako ekonomski razvoj napreduje, važnost usluga u gospodarstvu raste, dok uloga poljoprivrede opada. Istodobno, udio industrije kao postotak ukupne dodane vrijednosti povećava se u početnim fazama gospodarskog razvoja, ali nakon toga može slijediti različite obrasce, jer se često smatra da industrija čini visoke udjele ukupne vrijednosti ali to ovisi o stupnju razvijenosti zemlje. Između 2000. i 2018. godine, CESEE ekonomije slijedile su više manje stilizirani obrazac tranzicije. Slijedom toga, udio usluga kao postotka ukupne dodane vrijednosti porastao je, a poljoprivrede kao postotka ukupne dodane vrijednosti opao. Istodobno, udio industrije u postotku od ukupne dodane vrijednosti ostao je uglavnom nepromijenjen. Međutim, neka gospodarstva CESEE pokazuju strukturu koja pomalo odstupa od stiliziranih obrazaca. Neke su zemlje CESEE-a manje industrijski razvijene nego što bi se to dalo zaključiti za stupanj BDP-a po glavi stanovnika, ali to bi se odnosilo na neke zemlje koje su kandidati a ne članice Europske Unije u kojima poljoprivreda još uvijek ima izuzetno važnu ulogu. Istodobno, čini se da je većina razvijenih gospodarstava CESEE-a više industrijski razvijena od ostalih ekonomija u sličnoj fazi razvoja. U tim se zemljama relativna snaga industrijskog sektora može objasniti preusmjeravanjem

proizvodnje iz zapadne Europe koja je bila potaknuta visokim priljevima FDI-a, sve većim sudjelovanjem u globalnim lancima vrijednosti, nižim troškovima rada i blizinom naprednijih gospodarstava EU.

U mnogim zemljama CESEE-a i dalje ostaje značajan prostor za daljnju preraspodjelu radne snage u usluge i industriju. Iako je u nekim od ovih zemalja udio zaposlenosti u poljoprivredi već dostigao nisku razinu tipičnu za napredna gospodarstva, u drugim je i dalje relativno visok i tako smanjuje ukupnu produktivnost. Na primjer, udio zaposlenih u sektoru poljoprivrede u Rumunjskoj je oko 22%, dok udio poljoprivrede u ukupnoj dodanoj vrijednosti iznosi samo 4%. Među naprednijim gospodarstvima, prekomjerna zaposlenost u poljoprivredi posebno je izražena u Poljskoj, gdje poljoprivreda kao udio u ukupnoj zaposlenosti čini 11%, dok je ona jedva 2,7% u odnosu na ukupnu dodanu vrijednost.

3.4.2. Ljudski kapital

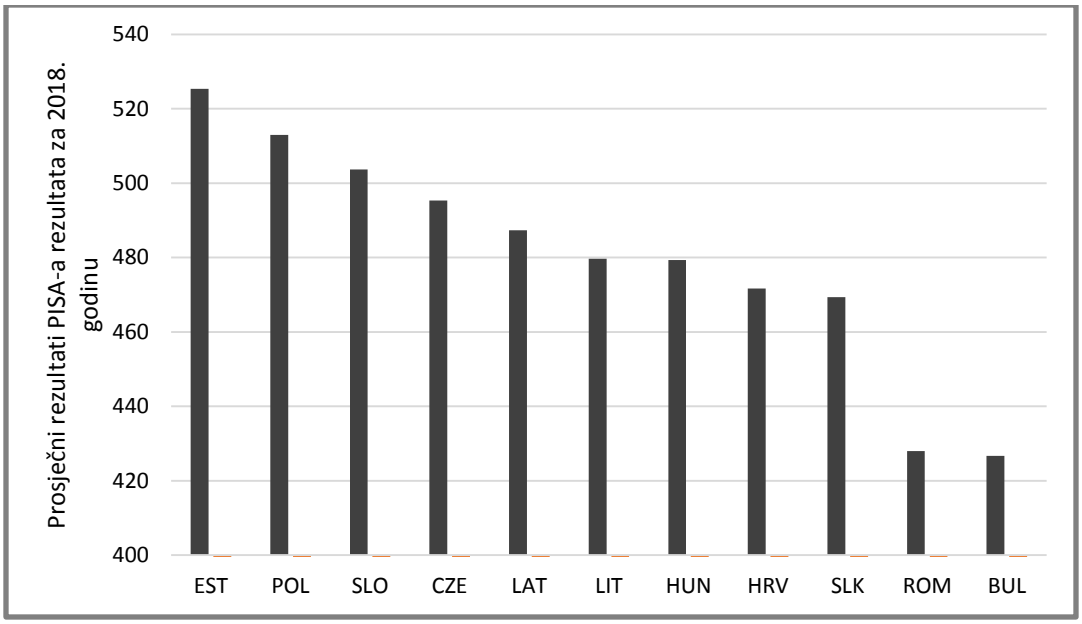
Čini se da je razina ljudskog kapitala u CESEE zemljama relativno visoka. Iako se pretpostavlja da je doprinos rada u pristupu proizvodnoj funkciji homogen, u stvarnosti kvaliteta rada znatno varira od zemlje do zemlje, što odražava razlike u ljudskom kapitalu. Stoga, kada se koristi pristup proizvodnoj funkciji, uz pretpostavku da je unos radne snage homogen, svaka promjena kvalitete rada dovodi do promjene neobjašnjive komponente gospodarskog rasta, koja se obično pripisuje ukupnoj faktorskoj produktivnosti. Iako se ljudski kapital ne može izravno promatrati, on se može aproksimirati varijablama poput postotka radne snage s visokim obrazovanjem ili stopom upisa u obrazovanje. U tim se mjernim podacima većina zemalja CESEE-a ostvaruje relativno dobro u usporedbi s prosjekom EU-a. Konkretno, udio stanovništva s najmanje ostvarenim stupnjem obrazovanja prvostupnik u baltičkim zemljama veći je, a u srednjoj i istočnoj Europi sličan prosjeku EU. Istodobno, postoje značajne razlike između zemalja na Balkanu i ostalih novih država članica EU-a, gdje je udio stanovništva s najmanje stupnjem prvostupnika i dalje relativno nizak, ali opet naravno visok kada se uspoređuje sa EU zemljama kandidatima.



Grafikon 11: Udio stanovništva s najmanje ostvarenom prvostupanjskom akademskom diplomom u čitavoj populaciji u 2018. godini

Izvor: Svjetska banka i Europska centralna banka

Upis u tercijarno obrazovanje povećao se u svim CESEE zemljama od 2000. godine, što ukazuje na rastući ljudski kapital mlađih generacija, što će vjerojatno povećati produktivnost i ekonomski rast u budućnosti te se u nekim zemljama omjer upisa značajno povećao. Omjer bruto upisa je omjer ukupnog broja upisanih stanovnika, bez obzira na dob, prema populaciji dobne skupine koji službeno odgovara razini prikazane razine obrazovanja. Sveukupno, 2015. godine u gotovo polovici zemalja CESEE-a omjer je bio iznad prosjeka EU-a od 68%, a premašio je 50% u gotovo svim zemljama regije. Bez obzira na ove pozitivne osobine, izazovi koji se odnose na kvalitetu obrazovanja i usklađivanje vještina s potražnjom na tržištu rada i dalje postoji u mnogim CESEE ekonomijama, posebno na Balkanu. U tom kontekstu, rezultati PISA-e, koji pokazuju kako 15-godišnji učenici rade u pogledu matematike, čitanja i naučnih vještina, ukazuju na relativno nisku kvalitetu obrazovanja novih EU zemalja članica, a posebno u Jugoistočnoj Europi. Suprotno tome, studenti su relativno uspješni u baltičkim zemljama i nekim zemljama srednje i istočne Europe, što ukazuje na visoku kvalitetu obrazovanja. Istodobno, usklađenost vještina s potrebama tržišta rada i dalje je slaba u većini CESEE gospodarstava (MMF, 2018), što pridonosi većoj neusklađenosti na tržištu rada i većoj nezaposlenosti.



Grafikon 12: Prosječni rezultat PISA-e iz matematike, čitanja i znanosti u 2018. godini (u dobi od 15 godina)

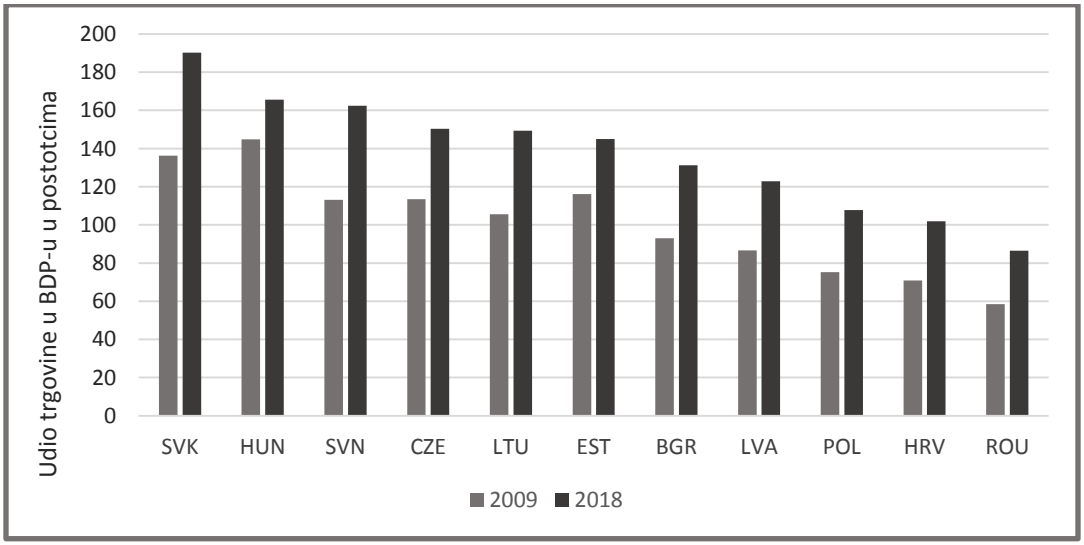
Izvor: European Inovation Scoreboard 2019

3.4.3. Trgovina i konkurentnost

Politika koja je otvorenija i više usmjerena vanjskim odnosima i trgovini može dugoročno podržati veći ekonomski rast, te prema ekonomskoj teoriji komparativnih prednosti i intenziteta faktora, povećani trgovinski tokovi omogućavaju preusmjeravanje resursa unutar sektora i specijalizaciju među zemljama, povećavajući tako učinkovitost i razinu prihoda. Nadalje, veća ekonomska otvorenost mogla bi otvoriti mogućnosti malim gospodarstvima da pristupe novim tržištima i iskoriste ekonomiju razmjera u proizvodnji. U skladu s tim također treba biti i oprezan, jer bi rastuća otvorenost trgovine mogla predstavljati i izazove povezane s npr. preusmjeravanjem radne snage iz sektora koji je okrenut uvozu ili potencijalno može stvoriti povećane nejednakosti u dohotku. Također, unatoč početnim dobicima povezanim s većom trgovinom, zemlje mogu biti zarobljene u proizvodnji roba i usluga u sektorima rasta s niskom produktivnošću, u kojima pokazuju komparativne prednosti (npr. niska vještina i proizvodi visokog radnog potencijala), što potencijalno onemogućuje konvergenciju prema najrazvijenijim gospodarstvima u dugom roku. Za opširniji pregled otvorenosti trgovine i njezinog potencijalnog

utjecaja na gospodarstvo pogledati Dollar (1992), Sachs i Warner (1995), Ben-David (1993), Edwards (1998), Rodriquez i Rodrik (2001) ili Rodriquez (2006).

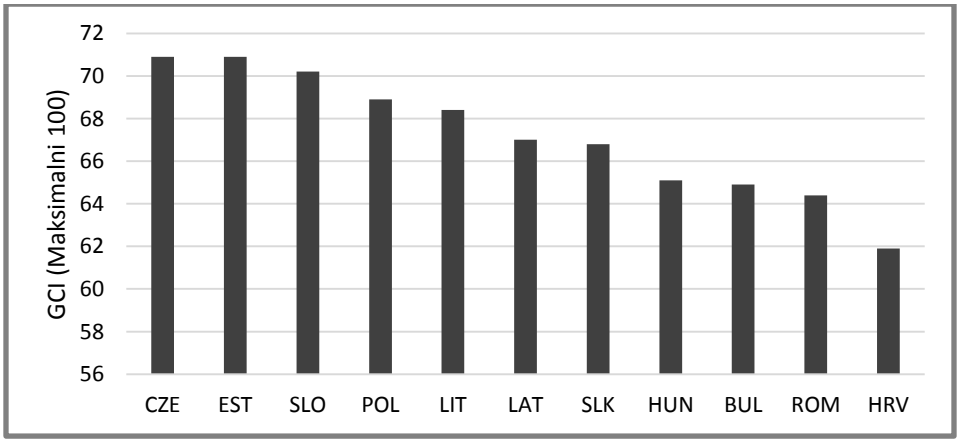
Otvorenost trgovine povećana je u gotovo svim zemljama regije CESEE od 2000. godine, stvarajući povoljne uvjete za konvergenciju prihoda u tim gospodarstvima. Najrazvijenija ili najbrže konvergentna CESEE gospodarstva (poput Češke, Estonije, Litve, Slovačke ili Slovenije) također pokazuju visoku otvorenost trgovine, ali visoki stupanj otvorenosti trgovine možda nije dovoljan za postizanje održivog procesa konvergencije, pogotovo ako nije popraćen poboljšanjem konkurentnosti. Zemlje CESEE-a koje su se pridružile eurozoni doživjele su najbrži rast otvorenosti trgovine od 2002. godine. Istovremeno povećanje otvorenosti trgovine u državama članicama EU izvan eurozone bilo je postupno, što bi se, međutim, moglo odražavati i na veće veličine tih gospodarstava. Suprotno tome otvorenost trgovine na Balkanu rasla je nešto umjerenije. Znatno brži rast izvoza nego uvoza bio je zajednička karakteristika u svim zemljama regije. U skladu s tim, gotovo sve nove države članice EU uspjele su pretvoriti trgovinski deficit u 2002. u trgovinske viškove do 2018. Međutim, ako se promatraju potencijalne EU zemlje članice koje su u dubokom trgovinskom odnosu sa navedenima, iako izvoz uglavnom raste brže od uvoza od 2002. godine, veliki vanjskotrgovinski deficit i dalje postoji. Ako se uzme u obzir da su značajni trgovinski deficiti tipični za sustizanje s ekonomijama, koje također privlače priliv kapitala, trgovinski debalansi u nekim zemljama na Balkanu mogu biti znakovi uske proizvodne baze i općenito niže konkurentnosti zemalja u regiji.



Grafikon 13: Trgovinska otvorenost u 2009. i 2018. godini.

Izvor: Svjetska banka i Penn World Tables 9.1

Promjene udjela CESEE ekonomija na svjetskom izvoznom tržištu koji se poprilično razlikuju od države do države, najbolji su pokazatelji sposobnosti da se natječu na globalnim tržištima. Na primjer, Poljska, Rumunjska, i Slovačka uspjele su snažno povećati svoj udio u svjetskom izvozu roba, te je nekoliko njih započelo proces iz relativno zatvorenog gospodarstva i niskog izvoza. S druge strane, države Baltika imale su snažan rast izvoza u godinama prije financijske krize 2008., dok je povećanje od tada umjereno. Mađarska, koja pokazuje jedan od najvećih omjera otvorenosti trgovine, nije uspjela povećati svoj udio u globalnom izvozu, što sugerira mali napredak u konkurentnosti. Glavno izvozno tržište većine CESEE gospodarstava tradicionalno je EU, koje u prosjeku predstavlja 70% robnog izvoza. Međutim, izvozna su odredišta postala raznovrsnija tijekom posljednjeg desetljeća, uključujući porast trgovine unutar regije. Indeksi vanjske konkurentnosti govore da je većina analiziranih ekonomija CESEE-a postigla lošije rezultate od prosjeka EU-a u svim mjernim podacima, bez obzira na poboljšanje u proteklom desetljeću. Čini se da regija CESEE ima posebne slabosti u institucijama, kvaliteti infrastrukture, tržištu rada i poslovne sofisticiranosti. Vanjska konkurentnost niska je na Balkanu, gdje tržišta rada trpi poteškoće u privlačenju i zadržavanju talenta, što ilustrira "odljev mozgova" i specifično iskustvo iseljavanja u posljednjem desetljeću. Nadalje, većina zemalja Balkana nije se uspjela pozicionirati kao kvalitetno odredište za realokaciju proizvodnih aktivnosti, za razliku od nekih novih država članica EU-a, koje su se uspjele integrirati u globalne multinacionalne lance nabave postajući odredištem proizvodne delokalizacije starijih država članica EU-a.

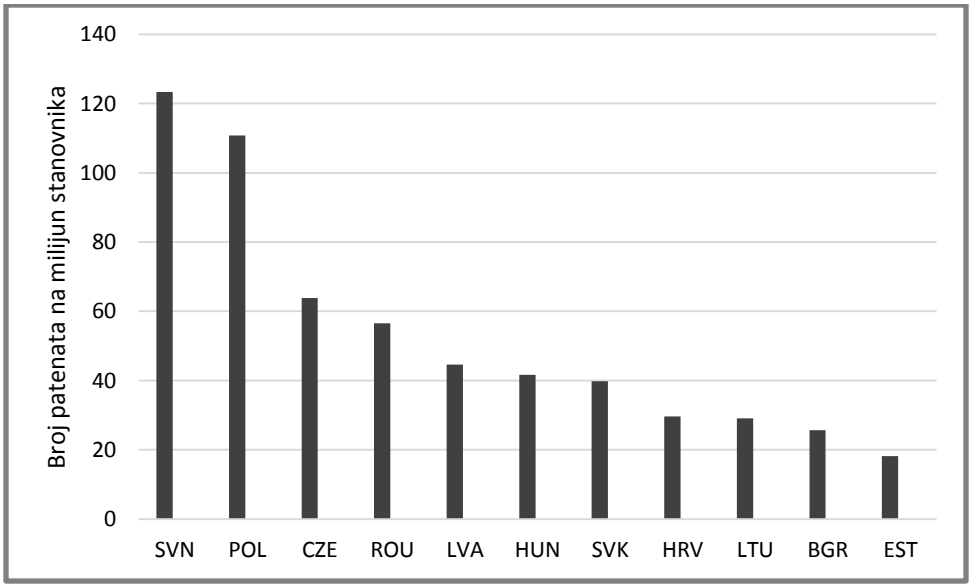


Grafikon 14: Globalni kompetitivni indeks u 2018. godini

Izvor: Svjetski ekonomski forum

3.4.4. Inovacije

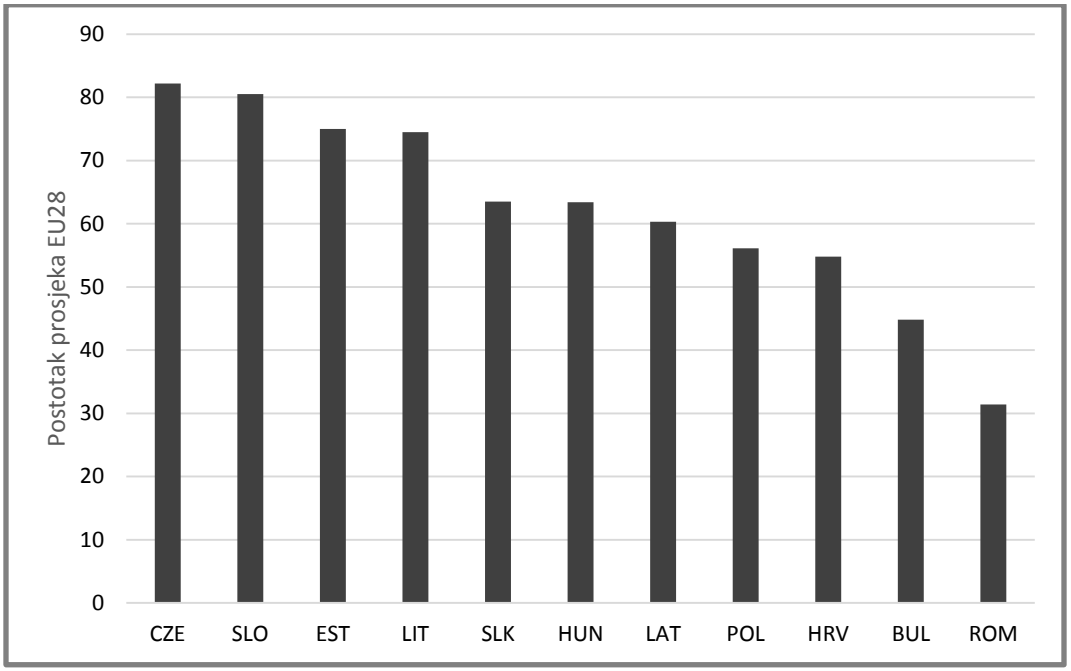
Ključni pokretač produktivnosti i rasta je inovacija, koja se također čini temeljnom za konkurentnost na globalnom tržištu proizvoda s višom dodanom vrijednošću. Iako zemlje s malim dohotkom mogu brzo konvergirati samo zbog nakupljanja kapitala, radne snage, uvoza tehnologija i znanja (kroz uvoz kapitalnih dobara ili izravna strana ulaganja), postizanje održive konvergencije može biti spriječeno nemogućnošću pomicanja proizvodnje od napornog rada do inovativnog i tehnološki naprednijeg procesa. Bez takvog strukturalnog pomaka, zemlje riskiraju da se zaglave u „zamci sa srednjim dohotkom“. U kontekstu CESEE zemalja, i one koje su već pristupile EU i one koje su trenutno kandidati za EU i potencijalni kandidati i one koji niti nisu kandidati, povećanje inovacija (i produktivnosti) također se čini temeljnim u kontekstu europskih integracija i sposobnosti da se natječu na jedinstvenom europskom tržištu i šire. Iako su posljednjih godina neke države CESEE uspjele dostići inovacije u odnosu na EU, druge su u određenoj mjeri zastale ili čak nazadovale. Ako se broj prijava patenata na milijun stanovnika koristi kao pokazatelj za inovacije, značajni se napredak može vidjeti u baltičkim zemljama, Poljskoj i Sloveniji od 2000. godine. Heterogeni razvoj inovacija u CESEE zemljama ukazuje na činjenicu da dobitci inovacija nisu automatski i da mogu zahtijevati provođenje politika koje podržavaju inovacije.



Grafikon 15: Rezidencijalne prijave patenata u 2018. godini

Izvor: Svjetska organizacija intelektualnog vlasništva

Kroz razdoblje 2000. do 2018. značajan je opseg poboljšanja među većinom zemalja CESEE, posebno u jugoistočnoj Europi. Prema europskom indeksu inovacija, razvrstavanjem gospodarstava prema inovacijskoj uspješnosti na temelju niza mjernih podataka, samo se Slovenija i Češka mogu svrstati u snažne inovatore, dok su većina gospodarstava CESEE klasificirana kao umjereni inovatori. Mjere indeksa inovacija obuhvaćaju, između ostalog, kvalitetne ljudske resurse, kvalitetu istraživanja, ulaganja u istraživanje i razvoj (R&R), intelektualnu imovinu, izvoz srednjih i visokotehnoloških proizvoda, zapošljavanje u značajnim aktivnostima itd. Snaga CESEE ekonomija uključuje ljudske resurse i okruženje pogodno za inovacije (posebice srednjoj i istočnoj Europi i baltičkim zemljama), a slabost je zaostajanje u pogledu kvalitete istraživanja, inovacija u malim i srednjim poduzećima (eng. SME – Small and medium enterpraises) vezanih za proizvode, procese, marketing i organizaciju), veze između inovativnih malih i srednjih poduzeća i istraživanja, veze između privatnog i javnog sektora i intelektualne imovine (mjereno npr. patentnim prijavama).



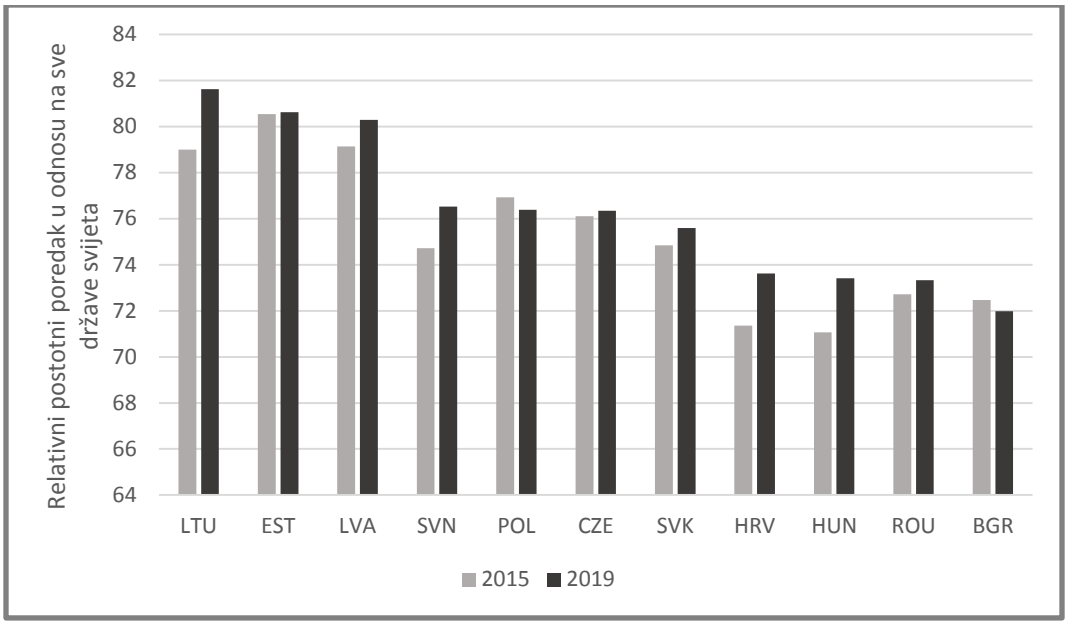
Grafikon 16: Tablica europske inovacije za 2018. kao postotak prosjeka EU28

Izvor: Europska komisija

3.4.5. Institucije

Kvaliteta institucija se često pretpostavlja kao temeljno objašnjenje gospodarskog rasta i dugoročno razlike u gospodarskom razvoju među zemljama (MMF, 2003; Acemoglu i sur., 2005; Rodrik, 2008). Shodno tome, može se primijetiti i jaka povezanost između kvalitete institucija i BDP-a po glavi stanovnika u skupini zemalja CESEE. Iako su institucije endogene, što znači da ih društvo određuje i da mogu biti u funkciji njegovih prihoda, njihovo unapređenje ne mora nužno nastupiti automatski kako napreduje ekonomski razvoj. Na primjer, Kaufmann i Kraay (2002) otkrili su snažan pozitivan uvjetovani učinak koji se kreće od boljeg upravljanja do većeg dohotka po glavi stanovnika; međutim, njihov je uvjetovani učinak u suprotnom smjeru (od dohotka po glavi stanovnika do upravljanja) bio slab i čak negativan. Institucije (tj. „pravila igre u društvu“) u regiji CESEE i njihov razvoj posljednjih desetljeća moraju se analizirati u kontekstu tranzicije navedenih zemalja od socijalističkog do tržišnog gospodarstva 1990-ih. Iako je tranzicija u većini država članica CESEE-a bila prilično brza i odvijala se uglavnom početkom 1990-ih, tempo tranzicije na Balkanu bio je mnogo sporiji. Taj razvoj u velikoj mjeri proizlazi iz “izgubljenog desetljeća“ zbog postjugoslavenskih ratova, koji su utjecali na reforme.

Uz prijelaz na tržišno gospodarstvo, institucije u zemljama CESEE-a postale su sve veća potpora rastu, najbrže se poboljšanje dogodilo u nekim gospodarstvima Balkana, i to s vrlo niskih razina, i u zemljama koje su se već pridružile eurozoni. Istodobno, institucionalna kvaliteta u nekim CESEE zemljama, nakon što se u početku poboljšala, nakon toga se pogoršala. Pristupanje EU-u predstavljalo je još jedan važan temelj institucionalnih reformi. U novim državama članicama EU najznačajniji napori u poboljšanju institucionalne kvalitete uloženi su u godinama prije pristupanja EU, dok je napredak nakon toga ograničen. To ukazuje na važnost izgleda pristupanja EU za zemlje kandidate za članstvo u EU i potencijalne kandidate za održavanje zamaha reformi s ciljem jačanja institucionalne kvalitete. Unatoč sveukupnim poboljšanjima institucionalne kvalitete, napredak je i raznolik u cijeloj regiji te stoga postoji znatan prostor za daljnji napredak u mnogim od njih. Većina CESEE zemalja zaostaje za EU28 u institucionalnoj kvaliteti. To se posebno odnosi na Hrvatsku, gdje je institucionalna kvaliteta i dalje niska zbog korupcije, neefektivne vladavine zakona i upitne regulatorne kvalitete.



Grafikon 17: Lakoća poslovanja u 2015. i 2019. godini

Izvor: Svjetska banka

Pristupanje EU važan je temelj institucionalnih reformi. Države CESEE-a koje su se pridružile eurozoni postigle su pozitivan reformski zamah posljednjih godina, i kao rezultat toga, institucionalna kvaliteta u tim zemljama približila se prosjeku EU, te to utječe na pozitivan razvoj s obzirom na povoljnije izglede za rast povezane s boljom institucionalnom kvalitetom i činjenicom da su snažne institucije ključne za osiguravanje održivosti konvergencije. Daljnje jačanje institucionalne kvalitete u tranzicijskim, novim EU zemljama članicama ostaje ključno ne samo za stvaranje povoljnih uvjeta za ekonomski rast, već osnažuje demokraciju i vladavinu zakona, unaprjeđuje funkcionalnost tržišnog gospodarstva i sposobnost da se nosi s pritiskom konkurencije i tržišnim silama unutar EU-a.

A) Odgovornost, pravo glasa i ekonomski rast

Politički sustav zemlje može biti demokratski ili autoritarni ili kombinirati elemente od oboje. U demokratskom sustavu sudjelovanje javnosti važno je u procesu izbora političkih lidera, a glas i odgovornost opisuju sudjelovanje javnosti u upravljanju. Ova je dimenzija upravljanja izravno povezana s demokracijom i transparentnošću, a demokracija u zemlji omogućuje ljudima da biraju svoje vladare glasom. U literaturi postoje tri glavne škole razmišljanja o tome kako

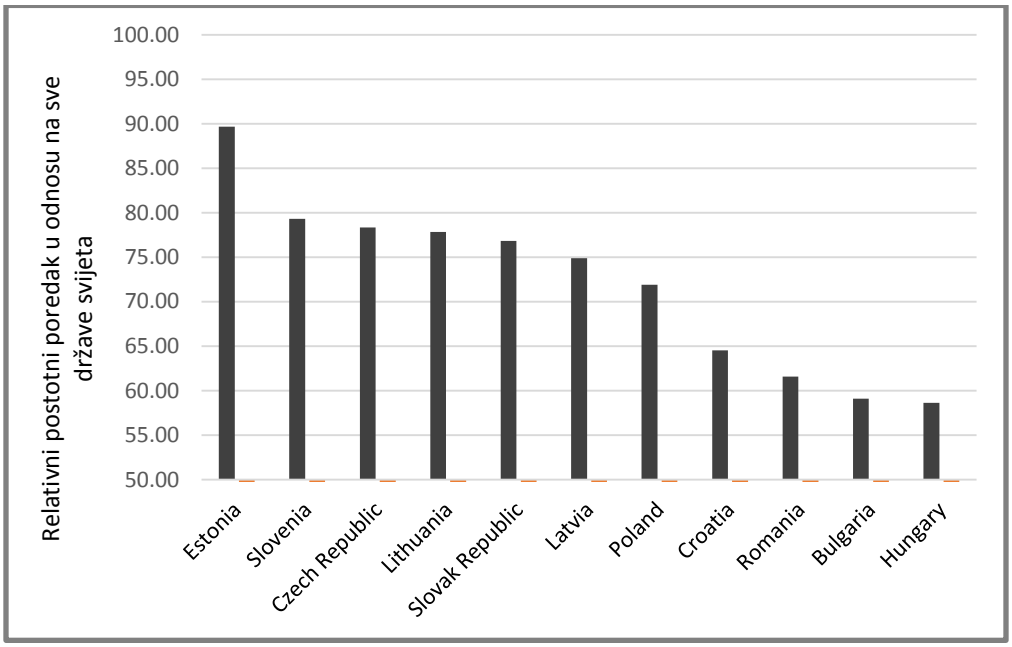
demokracija utječe na ekonomski rast (Sirowy i Inkeles, 1990). To su perspektiva sukoba, perspektiva kompatibilnosti i skeptična perspektiva.

Perspektiva sukoba teoretizira da se viši gospodarski rast može postići autoritarnim političkim režimom, jer je uspješna provedba reformi u demokratskom političkom sustavu teška. Ova teorija tvrdi da postoji kompromis između demokracije i gospodarskog rasta - ako neka država postigne višu razinu demokracije prije nego što dosegne graničnu razinu gospodarskog rasta, može se suočiti s poteškoćama u postizanju višeg nivoa ekonomskog rasta. Stoga je ispravan slijed prvo stvoriti ekonomski rast, a zatim uspostaviti veći standard demokracije (Sirowy i Inkeles, 1990). Većina zemalja u razvoju danas se suočava s poteškoćama u postizanju ekonomskog rasta u demokratskim režimima jer vlade u tim zemljama moraju donositi kratkoročne političke odluke kako bi udovoljile zahtjevima različitih društvenih grupa. Kao rezultat, kapacitet vlade će se smanjiti jer raspoređuje ogromne državne resurse da zadovolji različite društvene skupine umjesto da ih dodijeli za postizanje većeg rasta. U usporedbi s demokratskim režimima, autoritarne države mogu postići veći ekonomski rast zahvaljujući boljoj sposobnosti kontrole resursa i provođenju politike. Podupirući argumente Sirowy i Inkeles (1990.), Glaeser i sur., (2004.) tvrde da autoritarni režimi pomažu siromašnim zemljama u poboljšanju gospodarskog rasta, te nakon što su postigli određeni stupanj gospodarskog rasta, u drugoj fazi je potrebno doraditi političke institucije.

Perspektiva kompatibilnosti suprotna je perspektivi sukoba i ističe važnost demokracije i slobode u postizanju gospodarskog rasta. Demokracija i politička sloboda preduvjet su za pravilno izvršavanje ugovora, zaštitu zakona i reda i širenja tržišta radi postizanja snažnog gospodarskog rasta. Perspektiva kompatibilnosti naglašava nekoliko slabosti u perspektivi sukoba, poput sklonosti korupciji i otpadanju resursa, ograničenom kapacitetu centralno kontroliranih sustava i štetnim utjecajima na razvoj poduzeća.

Skeptična perspektiva usredotočena je na to kako neki demokratski temelji kao što su sustav političkih stranaka, politička kultura i korištenje resursa u industrijskim sektorima imaju neovisan utjecaj na ekonomski rast (Feng, 1997). U stvarnosti, i sukobi i gledišta kompatibilnosti važni su pojmovi u gospodarskom rastu. Demokracija doprinosi povećanom gospodarskom rastu

na dva načina, kao što su poticanje velikih promjena u redovnoj vlasti (promjene ustava) i obeshrabrivanje neustavnih promjena u vladi (Feng, 1997).



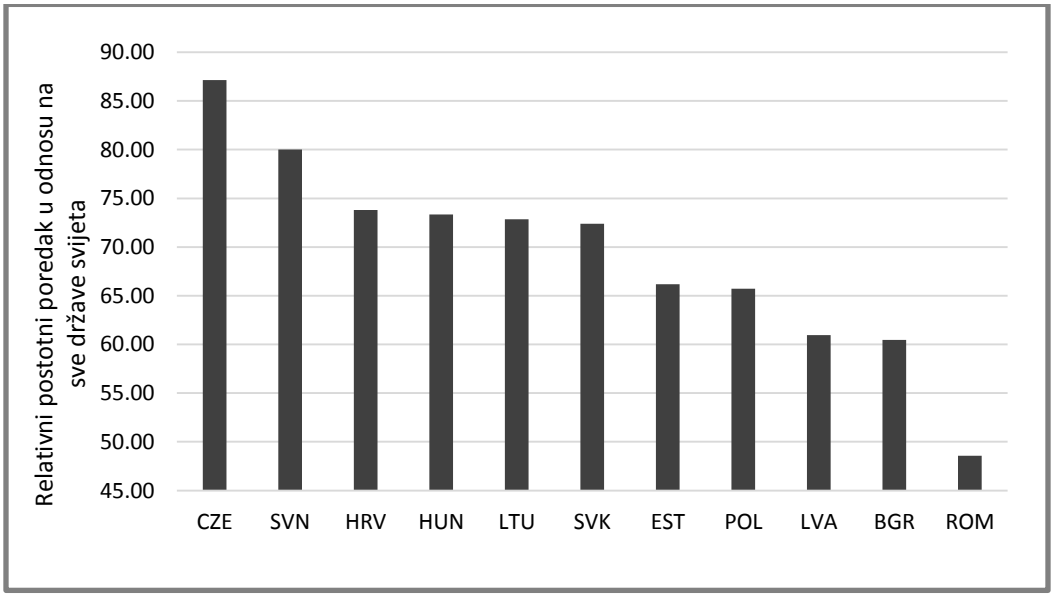
Grafikon 18: Pravo glasa i odgovornost među CESEE zemljama članicama EU-a u 2018. godini

Izvor: Svjetska banka

B) Politička stabilnost i odsutnost nasilja i terorizma

Politička stabilnost je potencijal za održavanje stabilne vlade bez utjecaja na ustavne ili neustavne promjene (Alesina i sur., 1992). Vlada ili politički režim mogu se mijenjati zbog glasačke moći ljudi unutar ustavnog okvira zemlje, ali se također politički režim može promijeniti zbog neustavnih akcija poput građanskog rata. S druge strane, Feng (1997.) tvrdi da se politička stabilnost zemlje može mijenjati zbog redovnih promjena vlasti i neredovnih promjena vlasti. Prema ovom mišljenju, redovna promjena vlasti slična je ustavnoj promjeni. Nepravilne promjene vlasti mogu se dogoditi zbog velikih nepravilnih promjena u vladi (npr. neustavne promjene) i manjih nepravilnih promjena (npr. promjena politike) (Feng, 1997). Neredovite političke promjene stvaraju neizvjesne uvjete za ulagače i samim tim se smanjuje gospodarski rast. Kao rezultat, u gospodarstvu se mogu pojaviti mnogi negativni utjecaji, kako kratkoročno, tako i dugoročno. Međutim, velike vladine promjene mogu pozitivno utjecati na

gospodarski rast ako nova vlada može stvoriti bolje okruženje za lokalne i strane ulagače smanjujući rizik zemlje i nudeći zdrave i dosljedne politike. Manja neredovna promjena uključuje promjenu politike. Promjene politike moraju se primijeniti uz održavanje političke stabilnosti i bez stvaranja investicijskog rizika (Feng, 1997.). Stabilno političko okruženje zemlje povećava akumulaciju ljudskog i fizičkog kapitala i time potiče proces rasta (Younis i sur., 2008).



Grafikon 19: Politička stabilnost i odsutnost nasilja i terorizma među CEESE zemljama članicama EU-a u 2018. godini

Izvor: Svjetska banka

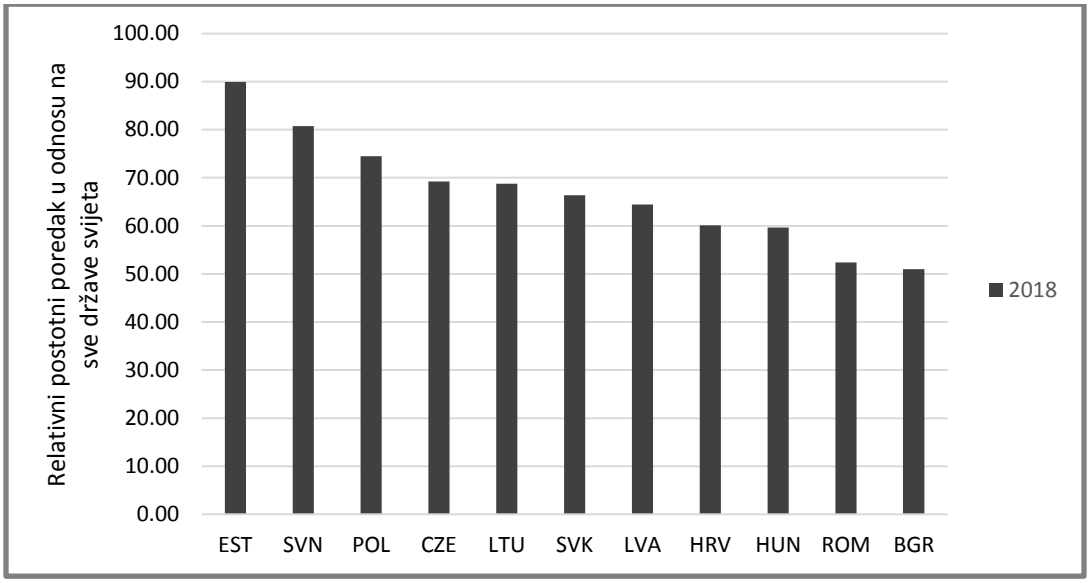
C) Suzbijanje korupcije

Korupcija je prodaja resursa, organizacije, isključivih informacija i moći odlučivanja od strane vladine stranke nevladinoj stranci (Andvig i Meone, 1990.). U korupcijskoj akciji postoji ponuda koja proizlazi iz vladine stranke i zahtjev koji proizlazi iz nevladine stranke (Andvig i Meone, 1990.). Kao što tvrdi Aidt (2009), ljudi imaju različito razumijevanje utjecaja upravljanja na gospodarski rast. Jedna skupina vjeruje da korupcija ima negativan učinak na gospodarski rast jer povećava transakcijske troškove i troškove proizvodnje. Ono što je najvažnije, korupcija će umanjiti povjerenje potrošača i povjerenja ulagača, te degenerirati povjerenje društva. Konačno, veća korupcija uzrokuje smanjenje ukupne institucionalne kvalitete određenog društva. Druga

skupina smatra da korupcija donosi poboljšanje ekonomskih učinaka uklanjanjem birokratskih uskih grla, poput kašnjenja u donošenju odluka u vezi s izdavanjem dozvola, odobrenja i provođenja ugovora (Aidt, 2009). Tanzi (1998) opisuje nekoliko uzroka zahtjeva i želja za korupcijom. Prvo, vlade provode pravila i propise za administrativne svrhe, koji uključuju pružanje licenci, dozvola i različitih vrsta ovlaštenja i inspekcija. Birokrati mogu tražiti mito koristeći svoje ovlasti za odgađanje odluka. Drugo, službenici koji upravljaju porezima ovlašteni su donositi odluke o poreznim olakšicama, poreznim obvezama i primjeni odgovarajućih propisa. Ova im moć omogućuje da se uključe u aktivnosti pogodovanja trećim subjektima u svrhu stjecanja osobne koristi. Treće, birokrati donose odluke o državnoj potrošnji i kupovini dobara i usluga i o javnim investicijskim projektima kao dijelom vladinih aktivnosti. U tim situacijama mogu tražiti mito od dobavljača. Četvrto, vlada nekim proizvodima i uslugama (obrazovanje, zdravstvo, voda, električna energija i javno stanovanje) pruža subvencioniranje javnosti što ostavlja prostor za političke malverzacije. Tanzi (1998) je identificirao mnogo razloga za opskrbu korupcijom, uključujući kvalitetu birokracije, plaće u javnom sektoru, kazne za korupciju, institucionalne mehanizme za kontrolu korupcije, transparentnost pravila i propisa za javnost te primjere koje je postavilo vodstvo. Postoje velike razlike u kvaliteti birokrata koji se očekuju od zemlje do zemlje. Evans i Rouch (1999) otkrili su značajnu pozitivnu vezu između gospodarskog rasta i birokratske kvalitete. Razine plaća u državnom sektoru igraju izuzetno relevantnu ulogu za smanjenje korupcije. Rijckeghem i Weder (1997) proučavali su odnos plaća u javnom sektoru i razinu korupcije, a rezultat je naglasio važnost povećanja plaća u državnom sektoru za smanjenje korupcije.

Nekoliko studija proučavalo je odnos između korupcije i ekonomskog rasta. Međutim, taj odnos varira od studije do studije i različite studije pokazuju potpuno različite rezultate. Pere (2015) je otkrio beznačajnu vezu između korupcije i ekonomskog rasta. Suprotno ovome, Mo (2001) zaključuje da je pad stope rasta za 0,72% uzrokovan porastom razine korupcije za 1%. Prema Aidtu, Dutti i Seni (2007), utjecaj korupcije varira od zemlje do zemlje u skladu s prevladavajućim političkim režimom. Može se tvrditi da je utjecaj korupcije štetniji za zemlje koje imaju zdrave političke institucije, dok se negativni učinci korupcije smanjuju u zemljama s korumpiranim političkim režimom. Mo (2001) je proučavao utjecaj korupcije na gospodarski rast kroz različite kanale. Prema njegovoj studiji, 53% ukupnog negativnog utjecaja korupcije na gospodarski rast doprinosi političkoj nestabilnosti. Uz to, razina korupcije jako ovisi o drugim

institucionalnim osobinama kao što su kultura i povijest (Treisman, 2000, Mo, 2001). Ata i Arvas (2011) tvrde da korupcija ima vezu s društvenim, ekonomskim, kulturnim i pravosudnim sustavima zemlje. Kao što je spomenuto u Treismanu (2000.), stupanj demokracije u nekoj zemlji ne utječe značajno na razinu korupcije. Pored toga, Mauro (1995.) je otkrio značajan negativan odnos između korupcije i investicija i ekonomskog rasta.



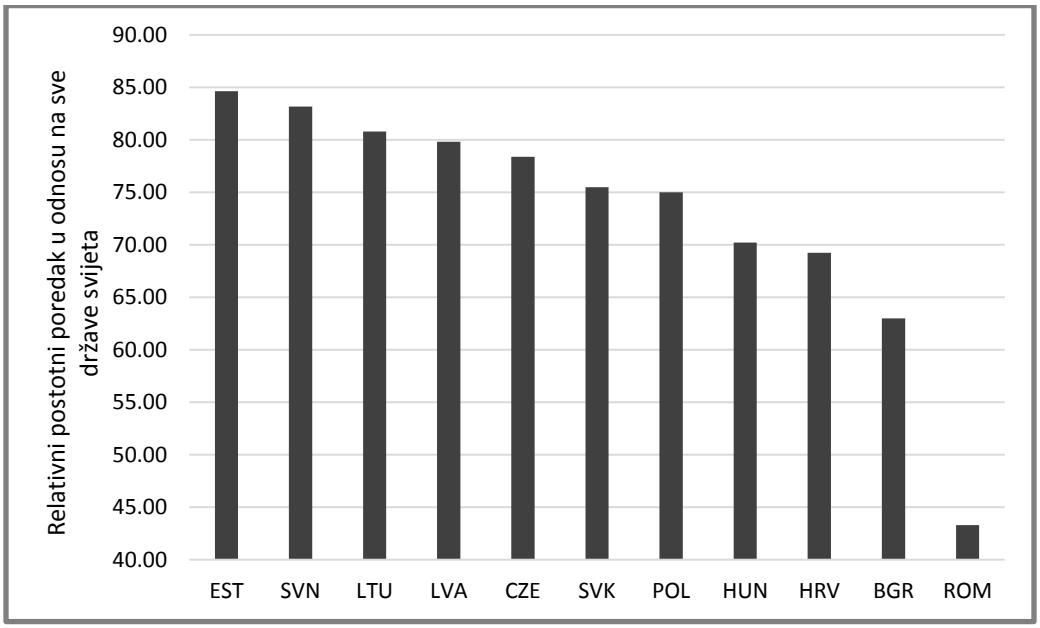
Grafikon 20: Borba protiv korupcije u CEESE-a zemljama članicama EU-a u 2018. godini

Izvor: Svjetska banka

D) Efikasnost vladavine

Dobrim upravljanjem i promicanjem učinkovitijih podjela rada, produktivnijim ulaganjima i bržom provedbom socijalnih i ekonomskih politika dolazi do većeg ekonomskog rasta. Prema Hall i Jones (1999), institucije i vladine politike određuju ekonomsko okruženje u kojem pojedinci akumuliraju vještine, a tvrtke akumuliraju kapital i razvijaju proizvode. Dok dobre vlade, učinkovitim pružanjem socijalne infrastrukture koja štiti od diverzije, mogu poboljšati ekonomski rast, loše vlade eksproprijacijom, konfiskacijskim oporezivanjem i lošim propisima i zakonima mogu stvoriti javnu diverziju u gospodarstvu. Prema tome, učinkovita vlada s jedne strane može poboljšati tržišnu učinkovitost, na primjer provođenjem vlasničkih prava, kako bi se pomoglo privatnom sektoru da potakne gospodarski rast, dok s druge strane, može nadopuniti privatni sektor u ekonomskom rastu ubrzavanjem akumulacije kapitala, usmjeravanjem resursa u

odgovarajuće sektore i pomaganjem apsorpciji i učenjem novih tehnologija (kako bi se osigurao rast produktivnosti), posebno u ekonomijama u kojima su tržišta strukturno vrlo slaba.



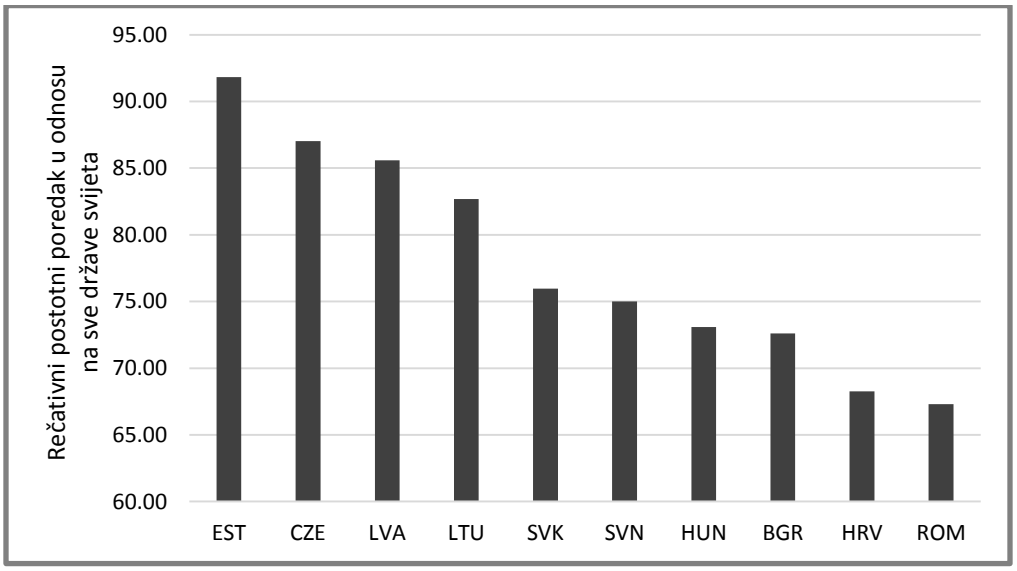
Grafikon 21: Efikasnost vladavine u CESEE zemljama članicama EU-a u 2018. godini

Izvor: Svjetska banka

E) Kvaliteta regulacije

Potreba za ekonomskom regulacijom zasniva se na postojanju nesavršenosti tržišnih mehanizama koji proizlaze od ekonomije razmjera i opsega proizvodnje, informacijske nesavršenosti u tržišnim transakcijama, postojanja nepotpunih tržišta i vanjskih utjecaja do rezultata učinka neravnomjerne raspodjele dohotka i bogatstva. Kvalitetna regulativa također je komplementarni pokazatelj upravljanja za vladinu učinkovitost, opisujući sposobnost vlade da donose učinkovite političke odluke za promicanje rasta privatnog sektora (Kaufmann, Kraay i Mastruzzi, 2010). La-Porta i sur., (1999) ističu važnost ograničene državne intervencije, kompetentne birokracije i legitimiteta imovinskih prava i provođenja ugovora u procesu ekonomskog rasta. Kao što kažu Easterly i Levine (1997), u raznim djelovima svijeta postoji ogromna raznolikost dohotka među etničkim skupinama, a jedan od obvezujućih čimbenika ove raznolikosti je neučinkovita javna politika. Nejednaka raspodjela javnih dobara utemeljena na

lošim javnim politikama može povećati nejednakost među različitim zajednicama i različitim etničkim grupama i time utjecati na ekonomski rast.

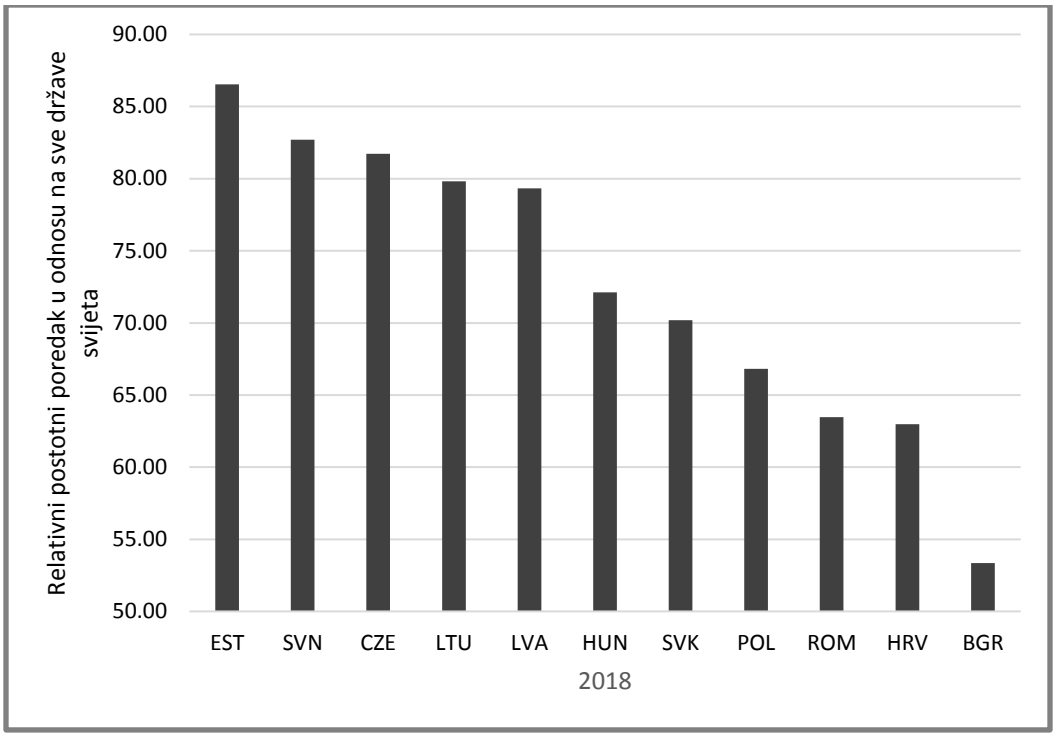


Grafikon 22: Kvaliteta regulacije u CESEE zemljama članicama EU-a u 2018. godini

Izvor: Svjetska banka

F) Vladavina zakona

Vladavina zakona odražava percepciju u kojoj mjeri agenti imaju povjerenja prema poštivanju pravila društva, posebno kvalitete izvršenja ugovora, imovinskih prava, policije i sudova, kao i vjerojatnosti kriminala i nasilja. Vladavina zakona važna je institucija u pogledu gospodarskog rasta jer se izravno povezuje s osiguravanjem osobne sigurnosti, imovinskih prava, nepristranim izvršavanjem ugovora i kontrolom korupcije (Haggard i Tiede, 2011). Vlada treba održavati zakon i red, sudsku neovisnost i kontrolu korupcije kako bi održala vladavinu zakona i izbjegla posljedice neuspjeha vlade. Rogobon i Rodrik (2004), Butkiewicz i Yanikkaya (2004) te Hoggard i Tiede (2011) naglašavaju pozitivan odnos između vladavine zakona i gospodarskog rasta. Djelovanje vladavine zakona u razvijenim zemljama mnogo je snažnije nego u zemljama u razvoju. Kada zemlje u razvoju trpe oštećenu vladavinu zakona, povećana je vjerojatnost korupcije, eksproprijacije i nasilja (Hoggard i Tiede 2011). Rogobon i Rodrik (2004) te Butkiewicz i Yanikkaya (2004) tvrde da i vladavina zakona i demokracija u kombinaciji zajedno igraju kritičniju ulogu u povećanju gospodarskog rasta, a ne samo vladavina zakona.



Grafikon 23: Vladavina zakona u CESEE zemljama članicama EU-a u 2018. godini

Izvor: Svjetska banka

.

4. EMPIRIJSKO ISTRAŽIVANJE UZROKA RAZLIČITOG STUPNJA BRZINE KONVERGENCIJE NOVIH EU ZEMALJA ČLANICA

U ovom su poglavlju predstavljeni rezultati procjena nekoliko jednostavnih modela kako bi se kvalitativna analiza provedena u prethodnim odjeljcima upotpunila kvantitativnim rezultatima. Modeli se temelje na uzorku svih CESEE ekonomija novih EU zemalja članica, a to su Estonija, Litva, Latvija, Poljska, Češka, Slovačka, Mađarska, Slovenija, Hrvatska, Rumunjska i Bugarska, analiziranih u razdoblju između 2002. i 2018. godine (godišnji podaci).

Testiraju se sljedeće hipoteze:

H1: Države sa većom akumulacijom kapitala imaju veći stupanj konvergencije od onih s manjom akumulacijom kapitala

H2: Države sa razvijenijim i učinkovitijim tržištem rada imaju veći stupanj konvergencije od onih s manje razvijenim i manje učinkovitijim

H3: Države sa bržim rastom ukupne faktorske produktivnosti imaju veći stupanj konvergencije od onih sa manjim rastom ukupne faktorske produktivnosti

Rast BDP-a po stanovniku u PPP-u bira se kao zavisna varijabla. U jednom od modela rast BDP-a izglađen je pomoću Hodrick-Prescottova filtra (s parametrom izravnavanja u iznosu od 7) da bi se uklonila cikličnost rasta BDP-a, te se zavisna varijabla u tim modelima smatra kao potencijalni rast BDP-a po glavi stanovnika. Izbor prediktora bio je zasnovan na kvalitativnoj analizi provedenoj u prethodnim odjeljcima i pregledu dosadašnje literature vezane za navedenu tematiku. Odabir neovisnih varijabli u regresiji rasta donosi niz izazova, a jedan od njih je izostavljanje varijabli koje bi mogle imati značajan utjecaj na rast. Suprotno tome, uključivanje svih značajnih varijabli možda neće biti moguće zbog ograničenog broja opažanja ili kratkog vremenskog niza ili može dovesti do kolinearnosti prediktora. Ocijenjena su dva različita modela sa fiksnim efektima, što se čini logičnim s obzirom da su modeli s fiksnim efektima prirodan izbor za skupinu zemalja, a kako bi to bilo potvrđeno, izvršen je Hausmanov test koji pokazuje da je model sa fiksnim efektima prikladniji nego sa slučajnim (Tablica 1.).

	Coefficients			
	(b) fixed	(B) random	(b-B) Difference	sqrt(diag(V_b-V_B)) S.E.
lagged_log~P	-33.79498	-16.20441	-17.59058	3.97923
Tertiary__~l	-.0104396	.024947	-.0353867	.0170632
DlAges_15_~l	-2.431123	.2587416	-2.689864	1.132599
DlPatent_M~n	-.0077431	-.0107769	.0030337	.
GCF__GDP	.3906127	.2569771	.1336356	.0135386
FDI__GDP	-.0196739	-.0359469	.016273	.
Trade__GDP	.0792202	.0254246	.0537956	.0180136
DlInst_AVG_T	4.077536	6.73776	-2.660224	.
Euro_Growth	1.164318	1.446812	-.2824934	.

b = consistent under Ho and Ha; obtained from xtreg
B = inconsistent under Ha, efficient under Ho; obtained from xtreg

Test: Ho: difference in coefficients not systematic

chi2(9) = (b-B)'[(V_b-V_B)^(-1)](b-B)
= 80.28
Prob>chi2 = 0.0000
(V_b-V_B is not positive definite)

Tablica 1: Hausmanov test

Ovi modeli kontroliraju sve vremenske karakteristike zemlje (neusklađene s individualnim karakteristikama drugih zemalja) koje mogu imati utjecaja i na neovisne varijable i na prediktore. Prema tome, prvi procijenjeni model je standardni model fiksnih učinaka za cijeli analizirani uzorak, s rastom BDP-a po glavi stanovnika filtriran HP-om kao regresiranom varijablom (n1_growth_all - Tablica 2). Drugi model procjenjuje se ponovo za cijeli uzorak zemalja, ali umjesto rasta BDP-a filtriranog od HP-a, stvarni rast BDP-a korišten je kao zavisna varijabla (GR_PC_PPP - Tablica 3).

Da bi se kontrolirala heteroskedastičnost u panel modelima se uobičajeno koriste čvrste standardne pogreške, međutim one ne rješavaju problem serijske korelacije (autokorelacije), a da bi se otkrio i riješio problem serijske korelacije, učinjeno je sljedeće: prvo je program STATA bio nadopunjen programskim dodatkom „xtserial“ koji pruža rezultate simulacije i pokazuje veličine i svojstva snage u uzorcima razumne veličine vezane za panel podatke koji prikazuju prisutnost serijske korelacije u navedenim modelima, a da bi riješili problem i serijske korelacije modeli su prikazani koristeći klasterirane standardne pogreške (eng. CSE – Clustered standard

errors). CSE posebne su vrste čvrstih standardnih pogrešaka koje se odnose na heteroskedastičnost u „klasterima“ opažanja (poput država ili pojedinaca). Klasteriranje se izvodi pomoću varijable koja je navedena kao fiksni efekt modela. Klasterirane standardne pogreške općenito se preporučuju pri analiziranju podataka na panelu, gdje se svaka jedinica promatra kroz vrijeme, te rješavaju problem heteroskedastičnosti i serijske korelacije. Da bi model bio stacionaran, korišteni su prvi diferencijali od tri različite varijable - udio radno sposobnog stanovništva u ukupnom stanovništvu, broj patenata na milijun stanovnika te indeks svjetske banke za institucije, nadalje, za testiranje stacionarnosti korišten je Levin-Lin-Chu test, koji nam prikazuje da su sve varijable koje su u modelima korištene stacionarne (Tablica 2.).

Levin-Lin-Chu unit-root test for GR_PC_PPP

Ho: Panels contain unit roots
Ha: Panels are stationary

AR parameter: Common
Panel means: Included
Time trend: Not included

ADF regressions: 1 lag
LR variance: Bartlett kernel, 8.00 lags

	Statistic	p-value
Unadjusted t	-8.9160	
Adjusted t*	-5.0647	0.0000

Levin-Lin-Chu unit-root test for lagged_log_

Ho: Panels contain unit roots
Ha: Panels are stationary

AR parameter: Common
Panel means: Included
Time trend: Not included

ADF regressions: 1 lag
LR variance: Bartlett kernel, 8.00 lags

	Statistic	p-value
Unadjusted t	-4.4482	
Adjusted t*	-3.0911	0.0010

Levin-Lin-Chu unit-root test for Tertiary__1

Ho: Panels contain unit roots
Ha: Panels are stationary

AR parameter: Common
Panel means: Included
Time trend: Not included

ADF regressions: 1 lag
LR variance: Bartlett kernel, 8.00 lags

	Statistic	p-value
Unadjusted t	-7.6829	
Adjusted t*	-4.4327	0.0000

Levin-Lin-Chu unit-root test for D1Ages_15_

Ho: Panels contain unit roots
Ha: Panels are stationary

AR parameter: Common
Panel means: Included
Time trend: Not included

ADF regressions: 1 lag
LR variance: Bartlett kernel, 8.00 lags

	Statistic	p-value
Unadjusted t	-3.0748	
Adjusted t*	-1.7789	0.0376

Levin-Lin-Chu unit-root test for D1Patent_Mi

Ho: Panels contain unit roots
Ha: Panels are stationary

AR parameter: Common
Panel means: Included
Time trend: Not included

ADF regressions: 1 lag
LR variance: Bartlett kernel, 8.00 lags

	Statistic	p-value
Unadjusted t	-11.8354	
Adjusted t*	-6.0430	0.0000

Levin-Lin-Chu unit-root test for GCF__GDP

Ho: Panels contain unit roots
Ha: Panels are stationary

AR parameter: Common
Panel means: Included
Time trend: Not included

ADF regressions: 1 lag
LR variance: Bartlett kernel, 8.00 lags

	Statistic	p-value
Unadjusted t	-6.5976	
Adjusted t*	-3.1095	0.0009

Levin-Lin-Chu unit-root test for FDI__GDP

Ho: Panels contain unit roots
Ha: Panels are stationary

AR parameter: Common
Panel means: Included
Time trend: Not included

ADF regressions: 1 lag
LR variance: Bartlett kernel, 8.00 lags

	Statistic	p-value
Unadjusted t	-6.8921	
Adjusted t*	-2.2002	0.0139

Levin-Lin-Chu unit-root test for Trade__GDP

Ho: Panels contain unit roots
Ha: Panels are stationary

AR parameter: Common
Panel means: Included
Time trend: Not included

ADF regressions: 1 lag
LR variance: Bartlett kernel, 8.00 lags

	Statistic	p-value
Unadjusted t	-4.9269	
Adjusted t*	-3.1075	0.0009

Levin-Lin-Chu unit-root test for D1Inst_AVG_

Ho: Panels contain unit roots
Ha: Panels are stationary

AR parameter: Common
Panel means: Included
Time trend: Not included

ADF regressions: 1 lag
LR variance: Bartlett kernel, 8.00 lags

	Statistic	p-value
Unadjusted t	-10.5808	
Adjusted t*	-4.7639	0.0000

Levin-Lin-Chu unit-root test for Euro_Growth

Ho: Panels contain unit roots
Ha: Panels are stationary

AR parameter: Common
Panel means: Included
Time trend: Not included

ADF regressions: 1 lag
LR variance: Bartlett kernel, 8.00 lags

	Statistic	p-value
Unadjusted t	-11.5697	
Adjusted t*	-7.6752	0.0000

Levin-Lin-Chu unit-root test for n1_growth_a		
Ho: Panels contain unit roots		
Ha: Panels are stationary		
AR parameter: Common		
Panel means: Included		
Time trend: Not included		
ADF regressions: 1 lag		
LR variance: Bartlett kernel, 8.00 lags		
	Statistic	p-value
Unadjusted t	-16.0766	
Adjusted t*	-12.5131	0.0000

Levin-Lin-Chu unit-root test for n1_growth_e		
Ho: Panels contain unit roots		
Ha: Panels are stationary		
AR parameter: Common		
Panel means: Included		
Time trend: Not included		
ADF regressions: 1 lag		
LR variance: Bartlett kernel, 8.00 lags		
	Statistic	p-value
Unadjusted t	-18.3565	
Adjusted t*	-14.6748	0.0000

Tablica 2: Levin-Lin-Chu „unit root“ testovi za sve zavisne i nezavisne varijable korištene u modelima

U modelu se koristi „Within“ a ne „Between“ procjenitelj zato što potonji nije u skladu modela s fiksnim već slučajnim efektima, te nadalje prilikom biranja između tri različite naredbe „Within“ procjenitelja, a to su „xtreg“, „areg“ i „OLS“, koristeći tablicu usporedbe parametara, dolazi se do zaključka da naredbe daju iste pretpostavke koeficijenata dok se klasterske robusne standardne pogreške jako blago razlikuju zbog korekcije razlike u malim uzorcima (odnos između vremenske i panel varijable), tako da u ovim modelima koristimo naredbu „xtreg“ koja je najpogodnija za panel podatke (Tablica 3.).

Nadalje, ka prvo, da bi se potvrdila hipoteza konvergencije, u model je uključen i logaritam zaostalog BDP-a po glavi stanovnika. Ako se hipoteza drži, koeficijent je negativan, što znači sporiji rast BDP-a kada je BDP po glavi stanovnika bio veći u prethodnom razdoblju. Za kontrolu utjecaja eksternih čimbenika koristi se rast BDP-a u eurozoni (u tablicama 4. i 5.– Euro_Growth i n1_growth_all). Istodobno je uključen pokazatelj otvorenosti zemlje (definiran kao zbroj izvoza i uvoza podijeljenog s BDP-om – u tablicama Trade__GDP) kako bi se istražio utjecaj trgovine na gospodarski rast. Na popis domaćih pokretača rasta uključene su investicije (u tablicama GCF__GDP) – eng. Gross capital formation), za koje se očekuje da će imati pozitivan utjecaj na rast BDP-a (i putem veće potražnje i pozitivnih učinaka ponude). Varijabla koja mjeri broj prijava patenata po BDP-u dodana je i kao posrednik u troškovima inovacija, istraživanja i razvoja, a očekuje se da će ova varijabla imati pozitivan utjecaj na gospodarski rast (u tablicama 4. i 5. D1Patent_Million).

Variable	ols	xtreg	areg
lagged_log~P	-33.794985***	-33.794985**	-33.794985***
Tertiary__~l	-.01043963	-.01043963	-.01043963
DlAges_15_~l	-2.4311228	-2.4311228	-2.4311228
DlPatent_M~n	-.00774313	-.00774313	-.00774313
GCF__GDP	.39061266***	.39061266***	.39061266***
FDI__GDP	-.0196739	-.0196739	-.0196739
Trade__GDP	.0792202***	.0792202**	.0792202***
DlInst_AVG_T	4.0775365	4.0775365	4.0775365
Euro_Growth	1.1643181***	1.1643181***	1.1643181***
_Ic_id_2	-5.8294272***		
_Ic_id_3	.17295664		
_Ic_id_4	-2.3788312		
_Ic_id_5	.42685012		
_Ic_id_6	-.90184476		
_Ic_id_7	3.5244125***		
_Ic_id_8	-2.7008581*		
_Ic_id_9	1.7418454		
_Ic_id_10	-1.6702445		
_Ic_id_11	-2.780672		
_cons	130.58307***	129.638**	129.638***
N	176	176	176
r2	.78530549	.77014378	.78530549
r2_A			

legend: * p<0.05; ** p<0.01; *** p<0.001

Tablica 3: Usporedba rezultata procjena parametara „xtreg“, „areg“ i „OLS“ naredbi „Within“ procjenitelja

Nadalje, kako bi se zabilježio utjecaj demografskih kretanja i promjena na razini ljudskog kapitala, omjer radno sposobnog stanovništva u ukupnom broju stanovnika (u tablicama 4. i 5. D1Ages_16__64_Total) i omjer upisanih u tercijarno obrazovanje (ukupan upis u tercijarno obrazovanje, bez obzira na dob, izražen u postotku stanovništva u dobnoj skupini koja službeno odgovara ovom stupnju obrazovanja – u tablicama Tertiary__Total) koriste se kao prediktori. Očekuju se pozitivni koeficijenti ove dvije varijable, uz upozorenje da indeks upisa u obrazovanje mjeri samo ljudski kapital mlađe populacije (s tim da je dio ostao izvan tržišta rada), pa bi njegov potencijalni utjecaj na rast BDP-a mogao biti malen ili neznačajan u kratkoročnom razdoblju. Kao zadnji prediktor, indeks isporuke Svjetske banke (eng. WDI – World bank

delivery index - prosjek četiri pokazatelja: regulatorne kvalitete, učinkovitosti vlade, kontrole korupcije i vladavine zakona – u tablicama 4. i 5. D1Inst_AVG_T) koristi se kao posrednik za institucionalnu kvalitetu. Očekuju se pozitivne vrijednosti koeficijenta, što znači da npr. bolja kontrola korupcije podržava ekonomski rast. Istovremeno treba naglasiti da bi poboljšanje institucionalne kvalitete moglo dugoročno više utjecati na ekonomski rast, a ključna je održivost poboljšanja institucionalne kvalitete.

```
Fixed-effects (within) regression               Number of obs      =       176
Group variable: c_id                            Number of groups   =        11

R-sq:  within  = 0.7701                         Obs per group: min =        16
       between = 0.1335                                        avg =      16.0
       overall = 0.5568                                        max =        16

                                                F(9,10)            =    133.17
corr(u_i, Xb)  = -0.5231                        Prob > F           =    0.0000

                                              (Std. Err. adjusted for 11 clusters in c_id)
------------------------------------------------------------------------------
             |               Robust
    GR_PC_PPP |      Coef.   Std. Err.      t    P>|t|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
lagged_log_GDPPPP |  -33.79498   7.430842    -4.55   0.001    -50.35193   -17.23804
  Tertiary__Total |  -.0104396   .0373308    -0.28   0.785    -.0936178    .0727385
D1Ages_15__64_Total |  -2.431123   1.945957    -1.25   0.240    -6.766985    1.904739
D1Patent_Million |  -.0077431   .0091346    -0.85   0.416    -.0280962    .0126099
        GCF__GDP |   .3906127   .0564192     6.92   0.000     .2649028    .5163225
        FDI__GDP |  -.0196739   .0132552    -1.48   0.169    -.0492083    .0098606
      Trade__GDP |   .0792202   .0231264     3.43   0.006     .0276913    .1307491
     D1Inst_AVG_T |   4.077536   3.152118     1.29   0.225     -2.94582    11.10089
      Euro_Growth |   1.164318   .1252556     9.30   0.000     .8852312    1.443405
            _cons |    129.638   29.18292     4.44   0.001     64.61441    194.6616
-------------+----------------------------------------------------------------
          sigma_u |   2.532068
          sigma_e |  2.1186121
              rho |  .58820511   (fraction of variance due to u_i)
------------------------------------------------------------------------------
```

Tablica 4: Rezultati regresije rasta za gospodarstva CESEE-a između 2002. i 2018.: model s fiksnim učincima bez filtriranih varijabli

Izvor: Svjetska banka, Penn World Table v9.2, ECB, IMF, Wiiw (FDI – baza statistike), Ujedinjeni Narodi, Svjetska organizacija za intelektualno vlasništvo (WIPO – baza statistike), Europska komisija

Fixed-effects (within) regression — Number of obs = 176
Group variable: c_id — Number of groups = 11

R-sq: within = 0.6986 — Obs per group: min = 16
between = 0.0159 — avg = 16.0
overall = 0.4139 — max = 16

F(9,10) = 1035.95
corr(u_i, Xb) = -0.6401 — Prob > F = 0.0000

(Std. Err. adjusted for 11 clusters in c_id)

nl_growth_all	Coef.	Robust Std. Err.	t	P>|t|	[95% Conf.	Interval]
lagged_log_GDPPPP	-17.74414	4.74183	-3.74	0.004	-28.3096	-7.178686
Tertiary__Total	.0130025	.0227982	0.57	0.581	-.0377951	.0638002
DlAges_15__64_Total	-1.327105	1.143206	-1.16	0.273	-3.874327	1.220118
DlPatent_Million	.0020013	.0085557	0.23	0.820	-.017062	.0210645
GCF__GDP	.2573549	.0492536	5.23	0.000	.147611	.3670987
FDI__GDP	-.008862	.0110712	-0.80	0.442	-.0335303	.0158063
Trade__GDP	.0838765	.0175105	4.79	0.001	.0448606	.1228924
DlInst_AVG_T	1.720064	1.763908	0.98	0.352	-2.210169	5.650297
nl_growth_euro	1.044551	.1293608	8.07	0.000	.7563175	1.332785
_cons	59.34586	17.91539	3.31	0.008	19.42789	99.26383
sigma_u	2.2234508					
sigma_e	1.7793025					
rho	.60961114	(fraction of variance due to u_i)				

Tablica 5: Rezultati regresije rasta za gospodarstva CESEE-a između 2002. i 2018.: model s fiksnim učincima sa filtriranim varijablama

Izvor: Svjetska banka, Penn World Table v9.2, ECB, IMF, Wiiw (FDI - baza statistike), Ujedinjeni Narodi, Svjetska organizacija za intelektualno vlasništvo (WIPO – baza statistike), Europska komisija

Rezultati regresije pokazuju da je većina koeficijenata ušla u jednadžbe s očekivanim znakovima, a rezultati procjene uvelike su slični u analiziranim modelima. Prije svega, rast BDP-a negativno je povezan s zaostalom razinom BDP-a po glavi stanovnika, što je u skladu s hipotezom β-konvergencije. Pokazalo se da je rast BDP-a u eurozoni snažno utjecao na gospodarski rast u CESEE zemljama, s multiplikatorom većim od jedan u oba slučaja. To znači da je za 1 postotni bod veći rast BDP-a u eurozoni praćen još većim rastom BDP-a u CESEE zemljama, što potvrđuje visoku važnost blizine naprednijih gospodarstava EU-a za gospodarski rast u CESEE zemljama. U isto vrijeme, veća otvorenost trgovine pozitivno je pridonijela rastu, prema rezultatima oba procijenjena modela. Nije iznenađujuće da je rast BDP-a u zemljama

CESSE-a bio pozitivno povezan s količinom formiranog kapitala, dok utjecaj stranih direktnih investicija (eng. FDI – Foreign Direct Investment) nije statistički značajan. Utjecaj inovacija - povezanih s brojem patenata na milijun stanovnika nemaju statistički značajan odnos u oba modela. Odnos između rasta i udjela radno sposobnog stanovništva nije bio u očekivanim granicama te iako njihov odnos u oba modela nije bio statistički značajan, u svim kontrolnim testovima on je bio negativnog predznaka i statistički značajan, što bi se moglo objasniti naglim iseljavanjem radno sposobnog stanovništva prema nekim visoko razvijanim članicama EU-a za vrijeme faze prosperiteta i višeg gospodarskog rasta u razdoblju od 2013. do 2018. godine na razini čitave EU. Odnos između rasta i ljudskog kapitala nije statistički značajan kao ni poboljšanje institucionalne kvalitete. Naime indeks kvalitete institucija od strane Svjetske Banke u sebi sadrži skupinu različitih indikatora, te je više njih imalo pad vrijednosti u vrijeme „Migrantske Krize“ koja se također zbivala paralelno s fazom ekonomskog prosperiteta na razini čitave EU, te se u tome krije dio objašnjenja što odnos institucija i rasta nije statistički značajan. U slučaju korištenja posebnih indikatora (npr. kontrola korupcije), vjerojatno bi veza bila pozitivna i statistički značajna, međutim to predstavlja samo dio indeksa institucija što nije dovoljno. Za provjeru navedenih podataka koristimo kontrolne testove u kojima su u svima uključene kontrolne varijable koje možemo smatrati egzogenima: udio radno sposobnog stanovništva, rast BDP-a u Eurozoni, bruto formiranje kapitala i zaostatak logaritma rasta BDP-a izraženog u PPP-u te po jedna endogena. Kontrolni testovi (prilog 1.) su u skladu sa regresijom te nema odstupanja i promjena statističke značajnosti niti smjera utjecaja različitih varijabli, osim u slučaju već navedenog odnosa rasta i udjela radno sposobnog stanovništva u ukupnom stanovništvu. Korelacija matrica i deskriptivna statistika dostupni su u prilogu rada (prilog 2. i prilog 3.).

Na temelju dobivenih rezultata:

Prva hipoteza - H1: Države sa većom akumulacijom kapitala imaju veći stupanj konvergencije od onih s manjom akumulacijom kapitala – se može prihvatiti što nam potvrđuju navedeni podaci iz regresije gdje je jasno vidljiv utjecaj visine udjela investicija u BDP-u na brzinu konvergencije, također treba naglasiti da FDI (strane direktne investicije) kao same nemaju značajan utjecaj na stupanj konvergencije.

Druga hipoteza - H2: Države sa razvijenijim i učinkovitijim tržištem rada imaju veći stupanj konvergencije od onih s manje razvijenim i manje učinkovitijim – se ne može prihvatiti što nam potvrđuju navedeni podaci iz regresije gdje je jasno vidljivo da udjel radno sposobnog u ukupnom stanovništvu nema značajan utjecaj na brzinu konvergencije novih EU zemalja članica.

Treća hipoteza - H3: Države sa bržim rastom ukupne faktorske produktivnosti imaju veći stupanj konvergencije od onih sa manjim rastom ukupne faktorske produktivnosti – se ne može prihvatiti što nam potvrđuju navedeni podaci iz regresije gdje je jasno vidljivo da stupanj visoko obrazovanih u ukupnom stanovništvu, razina inovacija i razvijenost institucija nemaju, a jedino otvorenost trgovine ima značajan utjecaj na brzinu konvergencije novih EU zemalja članica

U pogledu prema dosadašnjim istraživanjima počevši od Borys i sur. (2008.) rezultati ovog rada ne slažu se sa njegovim rezultatima da je temeljni utjecaj brzine konvergencije na području istočne i jugoistočne Europe pretežito rast Ukupne faktorske produktivnosti. Nadalje ovaj rad potvrđuje istraživanje Dvorokove (2014.) da se konvergencija novih članica EU nije prekinula nakon financijske krize, iako se mora naglasiti da se usporila. Tsanana i sur (2013.) pokazali su da CESEE države srednje Europe brže konvergiraju nego države jugoistočne Europe što je u skladu pogleda ovog rada na čitav period od 2002. do 2018. godine, ali treba naglasiti da se to ne može reći iz zadnjih nekoliko godina analiziranog razdoblja te bi trebalo raditi još detaljnije istraživanje posvećeno isključivo periodu od zadnjih pet godina na navedenu temu. Ovaj rad potvrđuje specifičnost svake države u istraživanju te se to slaže sa rezultatima od Dobrinsky i Halvik (2014.) koji analiziraju obrasce ponašanja država prije, za vrijeme te nakon završenih pregovora i članstva u EU. Iako ovaj rad nije analizirao proces i analizu formiranja različitih konvergencijskih klubova, potvrđuje se istraživanje od Borsi i Metiu (2015.) da regionalne veze igraju značajnu ulogu u formiranju sličnih obrazaca ponašanja različitih država članica, što se posebno može zaključiti iz promatranja država Baltika (Estonija, Litva i Latvija) centralne Europe (Slovačka, Češka) i jugoistočne Europa (Rumunjska i Bugarska). Oblath i sur. (2015.) te Grela i sur. (2017.) ukazuju na usporavanje brzine konvergencije novih EU članica nakon financijske krize, što je u skladu sa ovim istraživanjem. S obzirom na faktore i uzroke same konvergencije, ovo istraživanje naglašava da su stupanj ekonomske integracije sa EU i preusmjeravanje iz radno intenzivnih prema kapitalno intenzivnim djelatnostima glavni uzroci brzine konvergencije novih članica EU što je u skladu sa ekonomskom teorijom i velikom

većinom dosadašnjih istraživanja, ali s druge strane ovo istraživanje nije otkrilo pozitivnu vezu konvergencije i stanja na tržištu rada i stupnja obrazovanja što nije u skladu sa dosadašnjim istraživanjima, što se može objasniti raznim promjenama na tržištu rada posljednjih godina te internim i eksternim problemima s kojima se suočava Europska Unija.

Zemlje koje najbrže konvergiraju uključuju Litvu, Latviju i Rumunjsku. Istovremeno je konvergencija bila posebno spora u Sloveniji, Hrvatskoj, Mađarskoj i Češkoj. U potonjem nizu zemalja, Češka i Slovenija mogu činiti zasebnu skupinu: unatoč činjenici da je konvergencija bila prilično spora, ove dvije zemlje su i dalje najnaprednije ekonomije CESEE-a u pogledu prihoda po glavi stanovnika, s razinama bliskim prosjeku EU28. Sljedeće zajedničke karakteristike imaju najuspješnija gospodarstva CESEE-a u pogledu brzine konvergencije. Prvo, institucionalna kvaliteta znatno se poboljšala tijekom analiziranog razdoblja. Drugo, imali su vrlo brzo preusmjeravanje radne snage iz poljoprivrede u druge sektore s većom produktivnošću rada. Treće, osjetili su poboljšanu vanjsku konkurentnost (posljedično udjelom svjetskog izvoza na tržištu) i sve veću trgovinsku otvorenost. Ekonomije koje se najbrže približavaju također su pokazale vrlo značajno poboljšanje razine ljudskog kapitala ili je nivo ljudskog kapitala već bio jedan od najviših u regiji. Konačno, razina investicija također je bila veća od razina ostalih članica. Kada se analiziraju zemlje u pogledu konvergencije, jedna je upečatljiva karakteristika da su četiri zemlje s najsporijim tempom konvergencije već imale najvišu razinu dohotka po glavi stanovnika u 2000. godini (Češka, Hrvatska, Mađarska i Slovenija). U isto vrijeme, dok su se demografska kretanja, kretanje tržišta rada i ljudskog kapitala sveukupno mijenjala, napredak u vanjskoj konkurentnosti i inovacijama u mnogim od tih zemalja bio je spor u usporedbi s ostalim članicama. Većina njih također je doživjela malo poboljšanje institucionalne kvalitete (iako je u nekim od njih, posebno u Sloveniji, u 2000. godini bila već relativno visoka).

5. ZAKLJUČAK

Na temelju kvalitativne i kvantitativne analize provedene u radu mogu se izvući sljedeći zaključci. Između 2002. i 2018. sva analizirana gospodarstva CESEE-a uspjela su smanjiti razliku na prosjek EU28 u pogledu BDP-a po glavi stanovnika. Brzina konvergencije bila je, međutim, različita u svim zemljama i razdobljima. Većina CESEE zemalja koje su se već pridružile EU konvergirale su se relativno brzo, a neke od njih su već dostigle razinu BDP-a po glavi stanovnika blizu prosjeka EU28. U većini zemalja CESEE-a većina približavanja se dogodila prije krize, nakon čega je u većini zemalja usporen rast BDP-a i konvergencije prema naprednijim zemljama EU-a. Brzina konvergencije opadala je posebno u većini naprednih CESEE gospodarstava – Češka, Slovačka, Mađarska, Hrvatska, Rumunjska, Bugarska i Slovenija, dok su s druge strane Estonija, Litva, Latvija i Poljska nastavile rasti relativno brzo i nakon 2010. godine.

Od 2002. godine, ekonomski rast u zemljama CESEE-a uglavnom se temelji na akumulaciji kapitala te djelom na ukupnom rastu produktivnosti faktora, dok je doprinos promjena na tržištu rada u prosjeku bio blizu nuli. Računovodstvena analiza rasta pokazuje da je usporavanje rasta BDP-a nakon krize uglavnom bilo posljedica usporavanja ukupnog rasta produktivnosti faktora i akumulacije kapitala. Istodobno, obrasci rasta u novim državama članicama EU-a, iako slični prije krize, odstupili su nakon toga posebno zbog snažnog usporavanja rasta ukupne faktorske produktivnosti. Unatoč akumulaciji kapitala od 2002. godine, u većini gospodarstava CESEE-a kapitalne zalihe i dalje su znatno niže nego u prosjeku EU28. Iako je razina investicija bila relativno visoka prije krize, u velikoj mjeri potaknuta građevinskim procvatom i priljevima izravnih stranih ulaganja u razdoblju ograničene domaće štednje, ona su nakon toga smanjila. Posljedica toga je da je samo nekoliko CESEE zemalja uspjelo održati velika ulaganja posljednjih godina. Usporavanje ulaganja u CESEE posljedica je sporijeg rasta potencijalnog BDP-a, nižeg priljeva FDI-a i smanjenja građevinskih aktivnosti. Iako su temeljni demografski trendovi bili raznoliki, većina zemalja CESEE-a su doživjele iseljavanje. Gledajući unaprijed, očekuje se da će se izazovi vezani za opadajući udio stanovništva u radnom dobu povećati zbog ubrzanog starenja stanovništva. Negativne implikacije mijenjanja strukture stanovništva na tržište rada mogu se ublažiti povećanjem sudjelovanja u radu, koje je i dalje

malo u mnogim zemljama, posebno među mladima, ženama i starijim osobama. Izazovi koji se odnose na kvalitetu obrazovanja i usklađivanje vještina s potražnjom na tržištu rada postoje u mnogim CESEE ekonomijama. Nedostaci u razini produktivnosti (u usporedbi s naprednijim državama EU-a) također su povezani sa strukturom gospodarstva, a poljoprivreda niske produktivnosti u nekim zemljama i dalje predstavlja relativno značajan udio u ukupnoj dodanoj vrijednosti i zaposlenosti.

Gospodarski rast i konvergencija u CESEE gospodarstvima potpomognuti su sve većom otvorenošću i međunarodnom trgovinom, te su mnoga gospodarstva uspjela povećati svoju konkurentnost na globalnim tržištima, međutim, u nekim su se gospodarstvima ti udjeli povećavali samo umjereno i zadržao se visok deficit tekućeg računa što signalizira izazove povezane s vanjskom konkurentnošću. U zemljama s nižom vanjskom konkurentnošću također je konvergencija bila sporija. Inovacije su u većini zemalja CESEE ostale umjerene ili niske, dok su neke zemlje CESEE uspijevale postepeno povećati inovativnost, druge su zastale ili čak doživjele pad svoje inovativnosti u odnosu na prosjek EU28, stoga će transformacija prema inovativnijim i tehnološki naprednijim ekonomijama ostati jedan od najvećih izazova kako bi se postigla održiva konvergencija i izbjegla zamka sa srednjim dohotkom u budućnosti. Institucionalna kvaliteta u CESEE zemljama ostaje raznolika. Iako je u državama članicama EU-a koje koriste euro u prosjeku uglavnom slična prosjeku EU-a, ona zaostaje u zemljama CESEE-a koje još nisu u eurozoni te je u tom kontekstu stupanj integracije u EU važan temelj institucionalnih reformi. Zbog temeljne uloge institucionalne kvalitete u gospodarskom i još bitnije društvenom razvoju, njezino poboljšanje predstavljat će ključni izazov za ta gospodarstva u nadolazećem desetljeću. Na temelju analize provedene u ovom radu, može se ukazati na nekoliko zajedničkih karakteristika za najuspješnija gospodarstva CESEE-e u pogledu brzine konvergencije. Oni uključuju kao glavne pogone: Brzu preraspodjelu radne snage iz poljoprivrede u industriju i usluge, relativno visok udio ulaganja i poboljšanja vanjske konkurentnosti te rastuću trgovinsku otvorenost i snažne priljeve FDI-a, u kombinaciji sa poboljšanjem institucionalne kvalitete i razvojem ljudskog kapitala, povoljnog demografskog kretanja i visokom stopom sudjelovanja na tržištima rada. Cilj politike pojedinih članica trebala bi biti dugoročna usredotočenost na poticaj rasta kroz razvoj navedenih karakteristika u suradnji sa ostalim članicama EU-a.

LITERATURA

1. Acemoglu, D., Robinson, J. (2008): **The Role of Institutions in Growth and Development**, *Working Paper Series*, No 10, International Bank for Reconstruction and Development & World Bank on behalf of the Commission on Growth and Development, Washington D.C. dostupno na: https://siteresources.worldbank.org/EXTPREMNET/Resources/489960-1338997241035/Growth_Commission_Working_Paper_10_Role_Institutions_Growth_Development.pdf [18.05.2020.]
2. Atoyan, R., Christiansen, L., Dizioli, A., Ebeke, C., Ilahi, N., Ilyina, A., Mehrez, G., Qu, H., Raei, F., Rhee, A., Zakharova, D. (2016): **Emigration and Its Economic Impact on Eastern Europe**, *IMF Staff Discussion Note*, SDN/16/07. dostupno na: https://www.imf.org/external/pubs/ft/sdn/2016/sdn1607.pdf [18.05.2020.]
3. Barro, R.J., Sala-i-Martin, X. (1992): **Convergence**, *Journal of Political Economy*, Vol. 100, Issue 2, pp. 223-251. dostupno na: https://dash.harvard.edu/bitstream/handle/1/3451299/barro_convergence.pdf?sequence=4 [18.05.2020.]
4. Barro, R.J., Sala-i-Martin, X.I. (2004), *Economic Growth*, 2nd Edition, MIT Press, Cambridge (Mass.), dostupno na: http://sgpwe.izt.uam.mx/files/users/uami/atm/Libros/Robert_J._Barro_Xavier_Sala-i-Martin_Economic_gBookFi.org.pdf [18.05.2020.]
5. Bloom, D., Sousa-Poza A. (2013): **Ageing and Productivity**, *Labour Economics*, pp. 1-4. dostupno na: https://www.econstor.eu/bitstream/10419/71707/1/737838035.pdf [18.05.2020.]
6. Boozer, M., Ranis, G., Stewart, F., Suri, T. (2003): **Paths to Success: The Relationship between Human Development and Economic Growth**, *Discussion Paper* No 874, Economic Growth Center, Yale University, New Haven, dostupno na: http://www.econ.yale.edu/~granis/papers/brssjdesubfinal.pdf [18.05.2020.]
7. Damijan, J., Kostevc, Č., Rojec, M. (2013): **FDI, Structural Change and Productivity Growth: Global Supply Chains at Work in Central and Eastern European Countries**, *LICOS Discussion Paper Series* No 332. dostupno na:

http://www.grincoh.eu/media/serie_1__growth__structural_change__deve/grincoh_wp1.07_damijan_kostevc_rojec.pdf [18.05.2020.]

8. Diaz del Hoyo, J.L., Dorrucci, E., Heinz, F.F., Muzikarova, S. (2017): **Real convergence in the euro area: a long-term perspective**", *Occasional Paper Series*, No 198, ECB, Frankfurt am Main, December, dostupno na: https://www.ecb.europa.eu/pub/pdf/scpops/ecb.op203.en.pdf [18.05.2020.]
9. European Bank for Reconstruction and Development (2016): Transition Report 2016-17: *Transition for all – Equal opportunities in an unequal world*, London, dostupno na: https://www.ebrd.com/publications/transition-report-2016-17.pdf [18.05.2020.]
10. European Bank for Reconstruction and Development (2017): Transition Report 2017-18: *Sustaining Growth*, London, dostupno na: https://www.ebrd.com/publications/transition-report-201718.pdf [18.05.2020.]
11. European Comission (2020), *Annual macro-economic database*, dostupno na: https://ec.europa.eu/info/business-economy-euro/indicators-statistics/economic-databases/macro-economic-database-ameco/ameco-database_en [18.05.2020.]
12. European Comission (2020), *European innovation scoreboard database*, dostupno na: https://ec.europa.eu/docsroom/documents/36062/attachments/1/translations/en/renditions/native [18.05.2020.]
13. ECB (2015): **Real convergence in the euro area: evidence, theory and policy implications**, *Economic Bulletin*, Issue 5, July, dostupno na: https://www.ecb.europa.eu/pub/pdf/other/eb201505_article01.en.pdf [18.05.2020.]
14. ECB (2020), *Key euro area indicators database*, dostupno na: https://www.ecb.europa.eu/stats/ecb_statistics/key_euro_area_indicators/html/index.en.html [18.05.2020.]
15. International Monetary Fund (2003): **Chapter 3: Growth and Institutions**, *World Economic Outlook: Growth and Institutions*, IMF, Washington D.C., April, dostupno na: https://www.imf.org/~/media/Websites/IMF/imported-flagship-issues/external/pubs/ft/weo/2003/01/pdf/_chapter3pdf.ashx [18.05.2020.]
16. International Monetary Fund (2016): **Central, Eastern, and Southeastern Europe. How to Get Back on the Fast Track**, *Regional Economic Issues*, Washington D.C., May, dostupno na:

https://www.imf.org/external/pubs/ft/reo/2016/eur/eng/pdf/rei0516.pdf [18.05.2020.]

17. International Monetary Fund (2020): *World economic outlook database,* dostupno na: https://www.imf.org/external/pubs/ft/weo/2020/01/weodata/index.aspx [18.05.2020.]
18. Levine, R. (2005), "Finance and growth: Theory and evidence", in Aghion, P. and Durlauf, S., *Handbook of Economic Growth*, Vol. 1, dostupno na: http://faculty.haas.berkeley.edu/ross_levine/Papers/Forth_Book_Durlauf_FinNGrowth.pdf [18.05.2020.]
19. University of Groningen (2020), *Penn World Table version 9.1*, dostupno na: https://www.rug.nl/ggdc/docs/pwt91.xlsx [18.05.2020.]
20. North, D., Institutions, Institutional Change and Economic Performance, Cambridge University Press, 1990; Acemoglu, D., Johnson, S. and Robinson, J., "Institutions as a Fundamental Cause of Long-Run Growth", in Aghion, P. and Durlauf, S. (eds.), *Handbook of Economic Growth*, North Holland, Amsterdam, 2005: dostupno na: https://economics.mit.edu/files/4469 [18.05.2020.]
21. Organisation for economic cooperation and development (2020), *OECD.stat database,* dostupno na: https://stats.oecd.org/ [18.05.2020.]
22. Reinhart C.M., Rogoff K.S. (2009), 'The aftermath of financial crisis', NBER Working Paper, 14656, dostupno na: https://www.nber.org/papers/w14656.pdf [18.05.2020.]
23. Rodrik, D. (2000), "Institutions for High-quality Growth: What they are and how to acquire them", *NBER Working Paper*, No 7540. dostupno na: https://www.nber.org/papers/w7540.pdf [18.05.2020.]
24. Rodriquez F. (2006): **Openness and Growth: What Have We Learned?**, *World Economic and Social Survey*, United Nations, 2006, dostupno na: https://www.un.org/esa/desa/papers/2007/wp51_2007.pdf [18.05.2020.]
25. Romer, P.M. (1990), "Endogenous Technological Change", *Journal of Political Economy*, No 98 (5), dostupno na: https://www.nber.org/papers/w3210.pdf [18.05.2020.]
26. Silvestriadou, K., Balasubramanyam, V.N. (2000), "Trade policy, foreign direct investment, and convergence", *Review of Development Economics*, No 4(2), dostupno na: https://econpapers.repec.org/scripts/redir.pf?u=http%3A%2F%2Fepub.oeaw.ac.at%2F0xc1aa500d_0x00062025;h=repec:vid:yearbk:v:2:y:2004:i:1:p:133-154 [18.05.2020.]

27. Solow, R.M. (1956), "A Contribution to the Theory of Economic Growth", *Quarterly Journal of Economics*, Vol. 70 (1): 65-94. dostupno na: http://piketty.pse.ens.fr/files/Solow1956.pdf [18.05.2020.]
28. World Bank (2020), *World development indicators database*, dostupno na: https://databank.worldbank.org/source/world-development-indicators [18.05.2020.]
29. World Economic Forum (2019), *Global competitiveness database*, dostupno na: https://tcdata360-backend.worldbank.org/api/v1/datasets/53/dump.csv [18.05.2020.]
30. World Intellectual Property Organisation (2020), *Intellectuall property statistics database*, dostupno na: https://www.wipo.int/ipstats/en/ [18.05.2020.]
31. Żuk, P., Polgár, E.K., Savelin, L., Diaz del Hoyo, J.L., König, P. (2018): **Real convergence in central, eastern and south-eastern Europe**, *Economic Bulletin*, Issue 3, ECB, May, dostupno na: https://www.ecb.europa.eu/pub/pdf/other/ecb.ebart201803_01.en.pdf?11251773fa4b91219aa01b019c749f82 [18.05.2020.]

POPIS SLIKA

1. Sastavnice HDI-a 19

POPIS GRAFIKONA

1. Prosječna stopa rasta realnog BDP-a po stanovniku (PPP) u razdoblju 2002.-2018. 15
2. Realni BDP po stanovniku (PPP) u 2000, 2009 i 2018 godini 15
3. Potrebni potencijalni rast BDP-a s ciljem postizanja prosjeka svih EU članica do 2030-te godine 17
4. HDI i BDP u CESEE državama u 2018. godini 20
5. Kapital po radniku i produktivnost rada u 2018. godini u CESEE zemljama članicama EU-a 22
6. Stanovništvo u dobi od 15 do 64 godine u omjeru ukupnog stanovništva u 2000., 2009. i 2018. godini 24
7. Stopa radno aktivnog stanovništva u 2000, 2009 i 2018 godini 26
8. Prosječan broj djece po ženskoj osobi za razdoblje čitavog života 27
9. Udio migranata u ukupnom stanovništvu 28
10. Neto stanje migrantskog kretanja u odnosu na ukupno stanovništvo u 2018. 28
11. Udio stanovništva s najmanje ostvarenom prvostupanjskom akademskom diplomom u čitavoj populaciji u 2018. godini 31
12. Prosječni rezultat PISA-e iz matematike, čitanja i znanosti u 2018. godini (u dobi od 15 godina) 32
13. Trgovinska otvorenost u 2009. i 2018. godini 33
14. Globalni kompetitivni indeks u 2018. godini 34
15. Rezidencijalne prijave patenata u 2018. godini 35
16. Tablica europske inovacije za 2018. kao postotak prosjeka EU28 36
17. Lakoća poslovanja u 2015. i 2019. godini 38
18. Pravo glasa i odgovornost među CESEE zemljama članicama EU-a u 2018. godini 40
19. Politička stabilnost i odsutnost nasilja i terorizma među CEESE zemljama članicama EU-a u 2018. godini 41
20. Borba protiv korupcije u CEESE-a zemljama članicama EU-a u 2018. godini 43
21. Efikasnost vladavine u CESEE zemljama članicama EU-a u 2018. godini 44

22. Kvaliteta regulacije u CESEE zemljama članicama EU-a u 2018. godini 45
23. Vladavina zakona u CESEE zemljama članicama EU-a u 2018. godini 46

POPIS TABLICA

1. Hausmanov test 48
2. Levin-Lin-Chu „unit root“ testovi za sve zavisne i nezavisne varijable korištene u modelima 51
3. Usporedba rezultata procjena parametara „xtreg“, „areg“ i „OLS“ naredbi „Within“ procjenitelja 52
4. Rezultati regresije rasta za gospodarstva CESEE-a između 2002. i 2018.: model s fiksnim učincima bez filtriranih varijabli 53
5. Rezultati regresije rasta za gospodarstva CESEE-a između 2002. i 2018.: model s fiksnim učincima sa filtriranim varijablama 54
6. Kontrolni testovi procjenjenih modela 67
7. Korelacijska matrica 67
8. Deskriptivna statistika za sve zavisne i nezavisne varijable korištene u modelima 69

PRILOZI

Prilog 1. Kontrolni testovi

(Std. Err. adjusted for 11 clusters in c_id)

GR_PC_PPP	Coef.	Robust Std. Err.	t	P>|t|	[95% Conf.	Interval]
lagged_log_GDPPPP	-35.0296	7.756736	-4.52	0.001	-52.31269	-17.74652
DlAges_15__64_Total	-6.018108	2.048071	-2.94	0.015	-10.5815	-1.454721
GCF__GDP	.3776226	.0468647	8.06	0.000	.2732016	.4820437
Euro_Growth	1.280845	.1419791	9.02	0.000	.9644953	1.597194
Tertiary__Total	-.0080902	.0405908	-0.20	0.846	-.0985322	.0823517
_cons	143.9121	31.38779	4.58	0.001	73.97577	213.8485
sigma_u	2.7707804					
sigma_e	2.2236361					
rho	.60825201	(fraction of variance due to u_i)				

(Std. Err. adjusted for 11 clusters in c_id)

GR_PC_PPP	Coef.	Robust Std. Err.	t	P>|t|	[95% Conf.	Interval]
lagged_log_GDPPPP	-34.32675	7.136083	-4.81	0.001	-50.22693	-18.42656
DlAges_15__64_Total	-5.821913	2.055071	-2.83	0.018	-10.4009	-1.242929
GCF__GDP	.3895442	.0480973	8.10	0.000	.2823768	.4967116
Euro_Growth	1.271384	.136973	9.28	0.000	.9661888	1.576578
DlPatent_Million	-.0205902	.0093074	-2.21	0.051	-.0413284	.0001481
_cons	140.0871	29.73105	4.71	0.001	73.84218	206.332
sigma_u	2.7108239					
sigma_e	2.2089791					
rho	.60095461	(fraction of variance due to u_i)				

(Std. Err. adjusted for 11 clusters in c_id)

GR_PC_PPP	Coef.	Robust Std. Err.	t	P>|t|	[95% Conf.	Interval]
lagged_log_GDPPPP	-35.16858	7.264012	-4.84	0.001	-51.3538	-18.98335
DlAges_15__64_Total	-5.909699	2.111784	-2.80	0.019	-10.61505	-1.20435
GCF__GDP	.3817852	.0438816	8.70	0.000	.2840109	.4795594
Euro_Growth	1.290716	.1381543	9.34	0.000	.9828894	1.598543
FDI__GDP	-.0130412	.0104122	-1.25	0.239	-.036241	.0101586
_cons	143.9668	30.33415	4.75	0.001	76.37813	211.5555
sigma_u	2.7339509					
sigma_e	2.2218101					
rho	.60225052	(fraction of variance due to u_i)				

(Std. Err. adjusted for 11 clusters in c_id)

GR_PC_PPP	Coef.	Robust Std. Err.	t	P>|t|	[95% Conf.	Interval]
lagged_log_GDPPPP	-35.80696	7.051531	-5.08	0.000	-51.51875	-20.09517
D1Ages_15__64_Total	-2.795938	1.989951	-1.41	0.190	-7.229824	1.637949
GCF__GDP	.387691	.0588618	6.59	0.000	.2565387	.5188432
Euro_Growth	1.148761	.1268252	9.06	0.000	.8661769	1.431345
Trade__GDP	.0783953	.0249218	3.15	0.010	.022866	.1339246
_cons	137.7586	28.39716	4.85	0.001	74.48581	201.0314
sigma_u	2.5909252					
sigma_e	2.1168437					
rho	.599691	(fraction of variance due to u_i)				

(Std. Err. adjusted for 11 clusters in c_id)

GR_PC_PPP	Coef.	Robust Std. Err.	t	P>|t|	[95% Conf.	Interval]
lagged_log_GDPPPP	-34.14888	7.233063	-4.72	0.001	-50.26515	-18.03261
D1Ages_15__64_Total	-5.848232	2.056926	-2.84	0.017	-10.43135	-1.265115
GCF__GDP	.3740458	.0464273	8.06	0.000	.2705993	.4774922
Euro_Growth	1.298512	.1409388	9.21	0.000	.9844809	1.612543
D1Inst_AVG_T	4.472695	3.462684	1.29	0.226	-3.242646	12.18804
_cons	139.6386	30.17631	4.63	0.001	72.4016	206.8756
sigma_u	2.6798008					
sigma_e	2.2112525					
rho	.59492588	(fraction of variance due to u_i)				

Tablica 6: Kontrolni testovi procijenjenih modela

Prilog 2. Korelacijska matrica

Correlation matrix of coefficients of **xtreg** model

e(V)	lagged~P	Tertia~l	D1Ages~l	D1Pate~n	GCF__GDP	FDI__GDP	Trade_~P	D1Inst~T	Euro_G~h	_cons
lagged_log~P	1.0000									
Tertiary__~l	-0.3975	1.0000								
D1Ages_15_~l	0.7802	0.0777	1.0000							
D1Patent_M~n	-0.0412	0.0143	0.0387	1.0000						
GCF__GDP	-0.7050	-0.0107	-0.6798	-0.0811	1.0000					
FDI__GDP	-0.2074	-0.5096	-0.5382	-0.0666	0.5812	1.0000				
Trade__GDP	-0.3737	0.4401	0.1435	0.3125	0.3336	-0.0636	1.0000			
D1Inst_AVG_T	0.2483	0.0034	0.2865	0.3774	-0.3747	-0.1666	0.3171	1.0000		
Euro_Growth	0.0006	0.0669	0.2375	-0.3180	-0.3741	-0.3077	0.1899	0.2398	1.0000	
_cons	-0.9919	0.3170	-0.8368	0.0203	0.6917	0.2417	0.2652	-0.2850	-0.0083	1.0000

Tablica 7: Korelacijska matrica

Prilog 3. Deskriptivna statistika

GR_PC_PPP

	Percentiles	Smallest		
1%	-13.86304	-14.26877		
5%	-4.726983	-13.86304		
10%	-.9616359	-12.81044	Obs	187
25%	2.133258	-8.380321	Sum of Wgt.	187
50%	4.092854		Mean	3.696576
		Largest	Std. Dev.	4.251747
75%	5.568548	11.4401		
90%	8.367739	11.94653	Variance	18.07735
95%	10.11866	12.41448	Skewness	-1.254374
99%	12.41448	12.91914	Kurtosis	6.730979

lagged_log_GDPPPP

	Percentiles	Smallest		
1%	4.005325	3.970848		
5%	4.11698	4.005325		
10%	4.175645	4.0306	Obs	187
25%	4.256975	4.045988	Sum of Wgt.	187
50%	4.346389		Mean	4.326092
		Largest	Std. Dev.	.1110391
75%	4.413169	4.492655		
90%	4.457069	4.495479	Variance	.0123297
95%	4.472285	4.497605	Skewness	-.7373468
99%	4.497605	4.512828	Kurtosis	3.171845

Tertiary_%_Total

	Percentiles	Smallest		
1%	32.82408	32.08026		
5%	40.77352	32.82408		
10%	44.77801	33.88854	Obs	187
25%	52.01587	34.43736	Sum of Wgt.	187
50%	65.6241		Mean	63.00101
		Largest	Std. Dev.	13.31268
75%	71.39045	88.05743		
90%	80.26099	89.15319	Variance	177.2275
95%	85.51545	89.25217	Skewness	-.2105098
99%	89.25217	90.91087	Kurtosis	2.440535

DlAges_15__64_Total

	Percentiles	Smallest		
1%	-.7296884	-.7595183		
5%	-.656641	-.7296884		
10%	-.5765092	-.7247213	Obs	176
25%	-.443057	-.7088167	Sum of Wgt.	176
50%	-.1889587		Mean	-.1795431
		Largest	Std. Dev.	.307062
75%	.078252	.3759322		
90%	.2392525	.445695	Variance	.0942871
95%	.3173756	.4832489	Skewness	.1311314
99%	.4832489	.5097018	Kurtosis	2.058977

DlPatent_Million

	Percentiles	Smallest		
1%	-59.42519	-60.13247		
5%	-20.29193	-59.42519		
10%	-11.1628	-55.70317	Obs	176
25%	-4.709572	-31.58585	Sum of Wgt.	176
50%	.4010449		Mean	-.5434865
		Largest	Std. Dev.	12.59322
75%	6.067656	21.00496		
90%	11.10038	31.43915	Variance	158.5892
95%	16.92103	32.88608	Skewness	-1.547198
99%	32.88608	33.95992	Kurtosis	9.745135

GCF_%_GDP

	Percentiles	Smallest		
1%	18.10458	12.37117		
5%	19.16051	18.10458		
10%	19.58661	18.43991	Obs	187
25%	21.03194	18.44546	Sum of Wgt.	187
50%	24.21656		Mean	24.93069
		Largest	Std. Dev.	4.874519
75%	27.88716	39.0564		
90%	32.07228	39.85694	Variance	23.76093
95%	33.62237	40.01424	Skewness	.8626814
99%	40.01424	41.44911	Kurtosis	3.778482

FDI_%_GDP

	Percentiles	Smallest		
1%	-15.83879	-41.45758		
5%	-.5714933	-15.83879		
10%	1.016879	-8.501631	Obs	187
25%	2.059083	-4.22906	Sum of Wgt.	187
50%	3.626035		Mean	5.026352
		Largest	Std. Dev.	8.343013
75%	6.228596	31.24253		
90%	9.992947	47.49558	Variance	69.60586
95%	15.27714	50.46318	Skewness	2.044892
99%	50.46318	54.64873	Kurtosis	21.63509

Trade_%_GDP

	Percentiles	Smallest		
1%	56.17953	53.71025		
5%	69.43731	56.17953		
10%	79.62521	58.47283	Obs	187
25%	90.69187	59.36055	Sum of Wgt.	187
50%	122.7932		Mean	119.4023
		Largest	Std. Dev.	32.93452
75%	146.2959	181.6273		
90%	165.3806	184.5057	Variance	1084.682
95%	168.4897	188.0233	Skewness	.0117584
99%	188.0233	190.1551	Kurtosis	2.040928

D1Inst_AVG_T

	Percentiles	Smallest		
1%	-.1213501	-.1283807		
5%	-.076817	-.1213501		
10%	-.0598996	-.1059157	Obs	176
25%	-.0309408	-.1030265	Sum of Wgt.	176
50%	.0047636		Mean	.0082753
		Largest	Std. Dev.	.0553287
75%	.0461934	.1192009		
90%	.0859327	.1400067	Variance	.0030613
95%	.1065223	.1452776	Skewness	.2382476
99%	.1452776	.1696609	Kurtosis	2.885849

GR_PC_PPP cyclical component from hp filter

	Percentiles	Smallest		
1%	-13.64735	-15.7594		
5%	-5.79167	-13.64735		
10%	-1.854088	-12.78398	Obs	187
25%	-.8002312	-8.82958	Sum of Wgt.	187
50%	.1756153		Mean	-4.90e-09
		Largest	Std. Dev.	2.9804
75%	1.442503	6.564893		
90%	2.525115	6.568463	Variance	8.882784
95%	4.687656	6.731841	Skewness	-1.857035
99%	6.731841	6.918917	Kurtosis	10.81158

Euro_Growth cyclical component from hp filter

	Percentiles	Smallest		
1%	-4.682625	-4.682625		
5%	-4.682625	-4.682625		
10%	-1.190877	-4.682625	Obs	187
25%	-.4709888	-4.682625	Sum of Wgt.	187
50%	.063988		Mean	-2.63e-09
		Largest	Std. Dev.	1.481533
75%	.6409853	1.996643		
90%	1.664019	1.996643	Variance	2.194941
95%	1.996643	1.996643	Skewness	-1.569685
99%	1.996643	1.996643	Kurtosis	6.379872

Tablica 8: Deskriptivna statistika za sve zavisne i nezavisne varijable korištene u modelima

SAŽETAK

U radu se analizira konvergencija realnog dohotka u državama srednje, istočne i jugoistočne Europe (CESEE) koje su članice Europske Unije (EU) prema najnaprednijim gospodarstvima EU-a između 2002. i 2018. godine. Važnost ove teme ne proizlazi samo iz dalekosežnih implikacija realnog dohotka za ekonomsku dobrobit, već i od značaja konvergencije za ekonomsku i monetarnu integraciju s Europskom unijom i unutar nje.

U radu se utvrđuju stilizirane činjenice konvergencije i analiziraju pokretači gospodarskog rasta iz perspektive proizvodne funkcije, tj. akumulacija rada i kapitala i rasta ukupne faktorske produktivnosti, kao i faktori koji bi mogli imati određeni utjecaj na ove varijable. Na temelju kvalitativne i kvantitativne analize utvrđeni su čimbenici koji mogu objasniti razlike između gospodarstava u regiji koja se brzo i sporo konvergiraju. Najuspješnija gospodarstva CESEE-e u pogledu brzine konvergencije imaju zajedničke karakteristike. To između ostalog uključuje: otvaranje gospodarstva odraženog u rastućoj otvorenosti trgovine i priljev izravnih stranih ulaganja, stupanj integracije sa Europskom Unijom te rast vanjske konkurentnosti u kombinaciji sa poboljšanjem institucionalne kvalitete i ljudskog kapitala. Povoljni demografski razvoj i visoka stopa sudjelovanja na tržištu rada također su bitni čimbenici u gospodarskom rastu CESEE država.

Institucionalna kvaliteta i inovacije biti će osnova za ubrzanje i održavanje konvergencije u regiji u nadolazećem desetljeću, te će također, od velike važnosti biti i rješavanje izazova negativnih utjecaja starenja stanovništva.

Ključne riječi: Europska Unija, konvergencija, ekonomski rast

SUMMARY

This paper analyses the convergence of real income of countries in Central, Eastern and South-Eastern Europe (CESEE), which are members of the European Union (EU) according to the most advanced EU economies between 2002 and 2018. The importance of this topic stems not only from the far-reaching implications of real income for economic well-being, but also from the importance of convergence for economic and monetary integration with and within the European Union.

The paper identifies stylized convergence facts and analyses the drivers of economic growth from the perspective of the production function, i.e. the accumulation of labor and capital and the growth of total factor productivity, as well as factors that could have some influence on these variables. Based on qualitative and quantitative analysis, factors have been identified that can explain the differences between economies in the region that are converging rapidly and slowly. The most successful CESEE economies have common characteristics in terms of convergence rate. These include, but are not limited to: the opening of the economy reflected in growing trade openness and foreign direct investment inflows, the degree of integration with the European Union, and the growth of external competitiveness combined with improved institutional quality and human capital. Favourable demographic development and a high labor market participation rate are also important factors in the economic growth of CESEE countries.

Institutional quality and innovation will be the basis for accelerating and maintaining convergence in the region in the coming decade, and also, addressing the challenges of the negative impacts of an aging population.

Key words: European Union, convergence, economic growth