Trg J. F. Kennedya 6
10000 Zagreb, Croatia
Tel +385(0)1 238 3333
www.efzg.hr/wps
wps@efzg.hr

EFZG WORKING PAPER SERIES
EFZG SERIJA ČLANAKA U NASTAJANJU
ISSN 1849-6857
UDK 33:65

Br. 26-07

Vladmir Arčabić i Goran Markušić

Konvergencija na kredit? Apsorpcijski i konvergencijski kapacitet u EU – primjer Hrvatske i Portugala



Konvergencija na kredit? Apsorpcijski i konvergencijski kapacitet u EU – primjer Hrvatske i Portugala

Vladimir Arčabić
varcabic@efzg.hr
Ekonomski fakultet Zagreb
Sveučilište u Zagrebu
Trg J. F. Kennedy 6
10 000 Zagreb, Croatia

Goran Markušić
gmarkusic@net.efzg.hr
Ekonomski fakultet Zagreb
Sveučilište u Zagrebu
Trg J. F. Kennedy 6
10 000 Zagreb, Croatia

Stajališta iznesena u ovom članku u nastajanju stavovi su autora te ne predstavljaju stavove Ekonomskog fakulteta Zagreb. Članak nije prošao formalnu recenziju i odobrenje. Članak je objavljen kako bi dobio komentare o istraživanjima u tijeku, prije nego što se pojavi u konačnom obliku u akademskom časopisu ili na nekom drugom mjestu.
Rad je objavljen Zborniku radova 34. tradicionalnog savjetovanja Ekonomska politika Hrvatske u 2027. godini, Ježovita, Ana; Rogić Dumančić, Lucija (ur.). Opatija, 2026., str. 9-60., ISSN 1849-6482.

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

Copyright August 2023 by Vladimir Arčabić & Goran Markušić
Sva prava pridržana.
Dijelovi teksta mogu biti navedeni pod uvjetom da se u potpunosti navede izvor.

Sažetak

U radu se analizira postoji li konvergencija među zemljama EU te, važnije, kakav je sastav rasta koji vodi do konvergencije. Teza rada je da brzina konvergencije sama po sebi ne govori je li konvergencija dugoročno održiva, jer gospodarski rast može biti rezultat akumulacije rada i kapitala ili rasta produktivnosti. U radu predlažemo razlikovanje apsorpcijskog kapaciteta, mjerenog zbrojem doprinosa rada i kapitala rastu, od konvergencijskog kapaciteta, mjerenog zbrojem doprinosa ljudskog kapitala i ukupne faktorske produktivnosti. Procjenjuje se model uvjetne konvergencije za 27 članica EU u razdoblju od 2000. do 2025. te se provodi računovodstvo rasta za Hrvatsku i Portugal na temelju triju baza podataka: Penn World Table 11.0, EU KLEMS i AMECO. Rezultati potvrđuju uvjetnu konvergenciju, pri čemu su sredstva iz europskih fondova usko povezana s njezinom brzinom, a institucije određuju njezinu gornju granicu. Nismo pronašli dokaze o postojanju konvergencijskog zida pri pragu od 80 % prosjeka BDP-a po stanovniku, ali su doprinosi ljudskog kapitala i produktivnosti statistički značajni samo iznad tog praga. Portugal je proveo fazu infuzije, ali nije napravio prijelaz u fazu inovacije te pokazuje karakteristike zemlje u zamci srednjeg dohotka. Hrvatski konvergencijski kapacitet blizu je prosjeka EU, ali ispod razine usporedivih novih članica, uz iznimno snažnu epizodu između 2021. i 2023., dok od 2024. prevladava akumulacija rada i fizičkog kapitala. Povezanost isplata iz europskih fondova i produktivnosti nije statistički značajna, premda Hrvatska pokazuje blago pozitivnu vezu, za razliku od Portugala, gdje je veza blago negativna. Iz toga slijedi da sama stopa iskorištenosti sredstava iz EU fondova nije dostatna mjera uspješnosti kohezijske politike, već ju je potrebno nadopuniti podacima o konvergencijskom kapacitetu.

Ključne riječi

konvergencija; kohezijska politika; razvojna zamka; računovodstvo rasta; ukupna faktorska produktivnost; apsorpcijski i konvergencijski kapacitet; Hrvatska; Portugal

.

JEL classification

O47, O52, O43, F15, E22

1. Uvod

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

Središnja je ideja rada da brzina konvergencije ne govori o sastavu rasta koji dovodi do konvergencije. Ista stopa konvergencije može biti rezultat akumulacije fizičkog kapitala financiranog sredstvima EU ili rasta produktivnosti, a ta dva načina imaju bitno različite posljedice za održivost. Tu razliku u radu operacionaliziramo razlikovanjem apsorpcijskog i konvergencijskog kapaciteta. Apsorpcijski kapacitet je sposobnost gospodarstva da raspoloživa sredstva pretvori u rad i fizički kapital te se mjeri zbrojem njihovih doprinosa rastu. Konvergencijski kapacitet je sposobnost da se inputi pretoče u trajan rast produktivnosti, i mjeri se zbrojem doprinosa ljudskog kapitala i ukupne faktorske produktivnosti. Apsorpcijski kapacitet osigurava rast dok traje priljev EU sredstava, dok konvergencijski kapacitet osigurava rast koji preživljava njihov prestanak. Zamka srednjeg dohotka (ili razvojna zamka) mogu se u tom okviru definirati kao stanje visokog apsorpcijskog i niskog konvergencijskog kapaciteta.

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

Analiza se provodi na dvije razine. Prvo, na razini svih 27 članica procjenjuje se model uvjetne konvergencije za razdoblje od 2000. do 2025. godine, uz ispitivanje uloge sredstava iz europskih fondova i kvalitete institucija. Drugo, na razini pojedinih zemalja provodi se računovodstvo rasta, također za svih 27 članica, s detaljnim prikazom za Hrvatsku i Portugal. Portugal je odabran kao usporedna zemlja jer je nakon razdoblja uspješnog rasta pao ispod 80 % prosjeka BDP-a per capita

Europske unije i tamo se zadržao, što ga čini standardnim primjerom zemlje u razvojnoj zamci unutar EU. Računovodstvo rasta provodi se usporedno na tri baze podataka jer nijedna sama ne pokriva sve što je potrebno. Penn World Table 11.0 (Feenstra, Inklaar i Timmer, 2015) daje najdulju seriju te usluge kapitala i indeks ljudskog kapitala. EU KLEMS, izdanje 2023. (Bontadini i sur., 2023), jedini razdvaja kapital na informacijsko-komunikacijski, ostali materijalni i nematerijalni, čime omogućuje punu podjelu na tri komponente strategije 3i, ali za Hrvatsku ta podjela postoji tek od 2009. AMECO, proljetna verzija 2026. (Europska komisija, 2026), jedini pokriva razdoblje provedbe Mehanizma za oporavak i otpornost i seže do 2027.[1]

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

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

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

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

produktivnosti nije statistički značajna ni u jednoj od dviju zemalja, premda je nagib blago pozitivan za Hrvatsku i blago negativan za Portugal, što razlikuje zemlje međusobno.

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

2. Konvergencija i kohezijska politika

2.1 Proširenje EU i potreba za snažnijom kohezijom

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

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

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

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

Financijska perspektiva 2007 – 2013 obilježena je Globalnom financijskom krizom. Posljedica na funkcioniranje regionalne politike je reorijentacija od dugoročnog financiranja strukturnih nedostataka prema ublažavanju posljedica recesije. U financijskoj perspektivi 2014 – 2020, Europska komisija stavlja veći naglasak na rješavanje problema niske konkurentnosti EU uz istovremeno suočavanje sa klimatskim izazovima. Kasprzyk i Wojnar (2021) i Becker, W. i sur. (2020) ocjenjuju da je u Uniji došlo do napretka u postizanju svih ciljeva, ali postoje značajne razlike među članicama. Najbolji uspjeh su imale zemlje sjeverne Europe uz pojedine istočnoeuropske zemlje, dok su najgori rezultat imale mediteranske zemlje. U navedenim programskim razdobljima dolazi do reformi u načinu funkcioniranja regionalne politike gdje europski strukturni fondovi služe ne samo povećanju kohezije među članicama već i provođenje zajedničkih politika. Isto se nastavilo u financijskoj perspektivi 2021 – 2027, kada je dodatno uveden program *Next Generation EU* kao odgovor na COVID krizu. U posljednje tri financijske perspektive strukturnim fondovima je bilo namijenjeno 347 milijardi eura (za razdoblje 2007. – 2013.), 404 milijarde eura (za razdoblje 2014. – 2020.) i 368 milijardi eura (za razdoblje 2021. – 2027.) kako bi se smanjile regionalne razlike među članicama i provodile zajedničke politike.

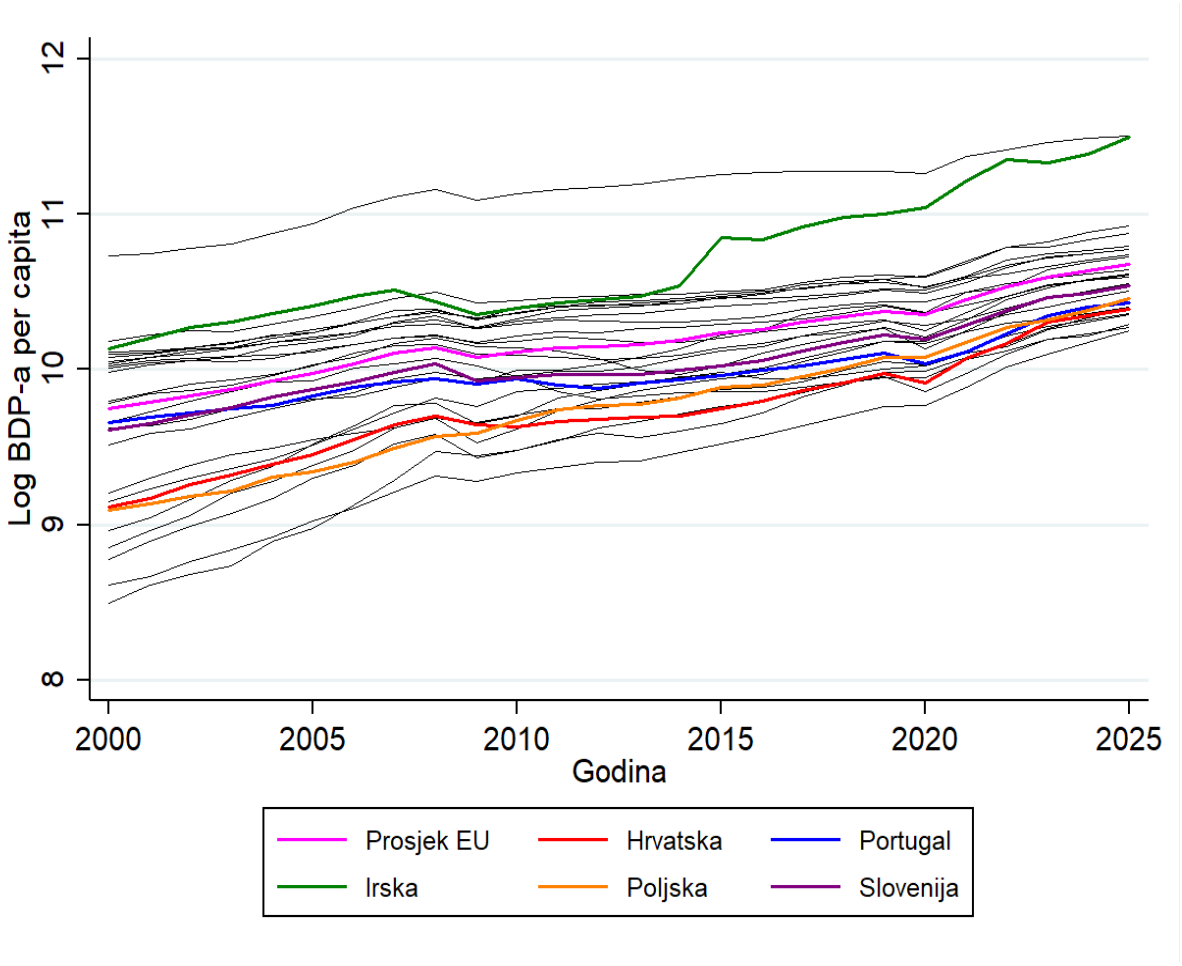
S obzirom na iznose posvećene koheziji, ali i sve dubljoj političkoj i ekonomskoj integraciji EU koja je prikazana kroz ovaj kratki pregled, postavlja se pitanje postižu li zemlje članice željene razine razvoja.

2.2 Održiva konvergencija ili konvergencija na kredit

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

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

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

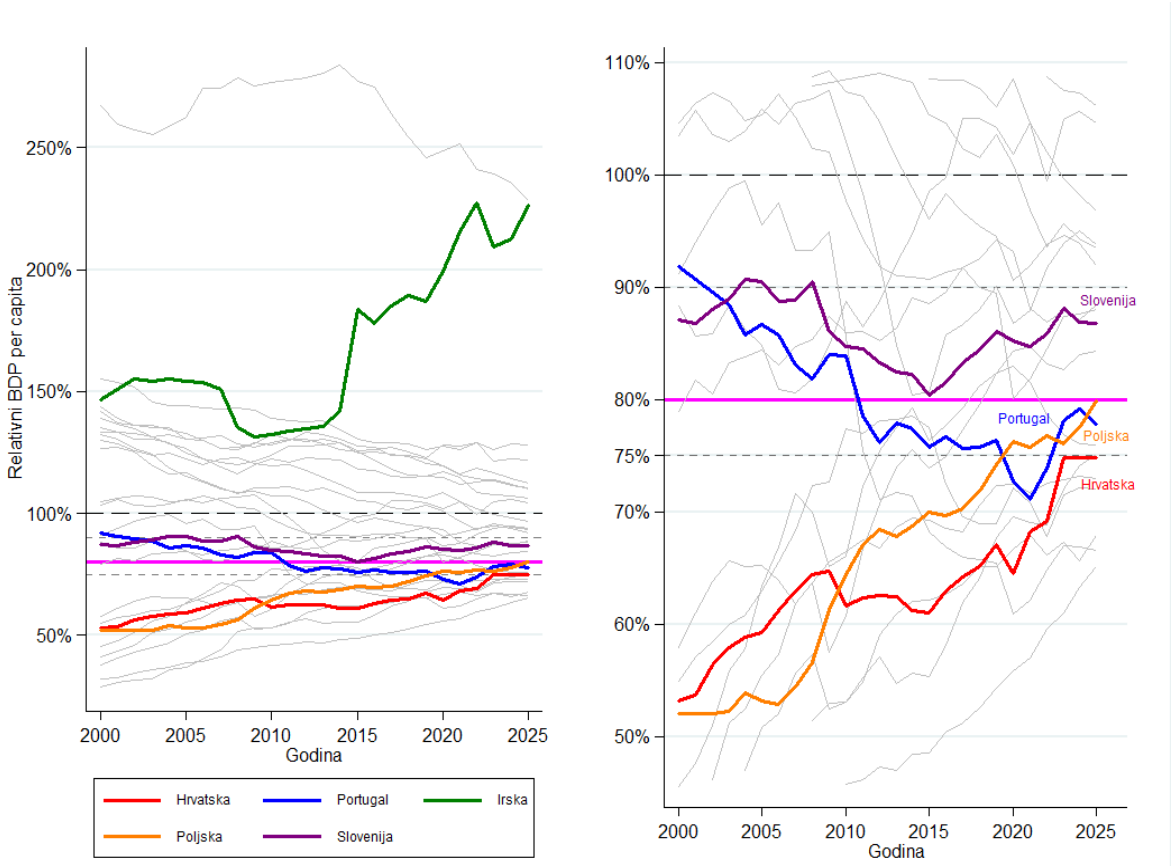


Izvor podataka: ARDECO baza

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

relativno smanjila, što dodatno upućuje na postojanje konvergencije, a time i na uspješnost kohezije u EU.[2]

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



Izvor podataka: ARDECO baza

Konvergencijski zid ili konvergencija na kredit

Druga perspektiva se pojavljuje ako se promatra relativni BDP per capita, odnosno BDP per capita u odnosu na EU prosjek. Na Slici 2 prikazana su dva panela koji prikazuju relativni udio BDP-a per capita u prosjeku EU. Prvi panel prikazuje cijeli raspon relativnih udjela za zemlje članice EU u razdoblju od 2000. do 2025. BDP per capita Luksemburga je značajno iznad prosjeka EU u cijelom promatranom razdoblju, ali s tendencijom pada. S druge strane, Irska je značajno povećala svoj BDP per capita relativno u odnosu na EU prosjek, djelomično i zbog promjene obuhvata nacionalnih računa. Ako promatramo cijeli skup zemalja, vidljivo je da je raspršenost oko prosjeka bila veća u 2000. i smanjuje se do 2025. što ponovno ide u prilog tezi o postojanju konvergencije unutar EU. Pritom se relativni udio BDP-a per capita zemalja koje su bile iznadprosječne u 2000. postupno smanjuje, a ispodprosječnih

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

zemalja povećava. Isto ide u prilog konvergencijskom modelu gdje bogatije zemlje imaju niže stope rasta od siromašnijih stoga se i njihov relativni udio smanjuje.

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

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

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

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

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

Dodatan razlog zbog kojeg se zid na 80 % teško uočava u podacima proizlazi iz nalaza Cerque i Pellegrinija (2023). Autori izravno ispituju što se događa s regijama koje izgube status konvergencijske regije i time dožive pad priljeva sredstava iz kohezijske politike. Rezultati pokazuju da u prosjeku ne postoji oštar prekid rasta u trenutku prelaska praga prihvatljivosti (tj. „zid“), nego dugoročno pozitivan učinak sredstava koji traje dulje od samih priljeva. Autori pritom naglašavaju da je učinak izrazito heterogen i ovisan o obilježjima regije i lokalnom gospodarskom kontekstu, kao i o fazi ciklusa u kojoj do smanjenja sredstava dolazi. Upravo ta heterogenost i osjetljivost na makroekonomski kontekst dodatno otežavaju identifikaciju praga: ako se stagnacija javlja samo kod dijela zemalja i samo u nepovoljnim uvjetima, prosječni će učinak biti statistički neznačajan iako pojedinačne putanje, poput portugalske, upućuju na zaustavljanje konvergencije.

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

Održivost konvergencije

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

Formalna procjena modela uvjetne konvergencije za 27 zemalja članica EU u razdoblju od 2000. do 2025. prikazana je u Tablici 1. Procjenjuje se model uvjetne beta konvergencije sa stopom gospodarskog rasta kao zavisnom varijablom i sljedećim nezavisnim varijablama: inicijalna razina BDP-a per capita

(definirana kao pet vremenskih pomaka unatrag i izraženo u paritetu kupovnog standarda), investicije (izraženo u paritetu kupovnog standarda), stopa rasta stanovništva, ljudski kapital mjeren kao udio stanovništva sa tercijarnim obrazovanjem, ukupna faktorska produktivnost (TFP), stopa zaposlenosti i Indeks ekonomskih sloboda kao mjera institucionalne kvalitete.

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

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

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

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

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

Broj promatranja	648	234	414
R-kvadrat	0.635	0.701	0.659
Broj zemalja	27	12	20
FE - zemlje	Da	Da	Da
FE - godine	Da	Da	Da

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

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

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

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

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

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

jednom trenutku mora biti zamijenjena fazama usvajanja tehnologije i inovacija koje počivaju upravo na ljudskom kapitalu i produktivnosti.

2.3 Strukturni fondovi, kvaliteta institucija i konvergencija

Pregled literature

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

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

Analiza utjecaja strukturnih fondova na konvergenciju

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

Podaci

Istraživanje obuhvaća 214 NUTS 2 regija u razdoblju od 2002. do 2018. godine. U istraživanju su korištene sljedeće varijable: stopa rasta BDP-a per capita regija, inicijalna razina BDP-a per capita regije

(definirana kao razina BDP-a per capita pomaknuta pet perioda unatrag), udio investicija u BDP-u, stopa rasta stanovništva, stopa zaposlenosti, udio ukupnog iznosa plaćanja iz EU fondova u BDP-u (ukupna plaćanja se odnose na zbroj izdataka iz fondova ERDF, ESF, CF, EAFRD, EMFF, FEAD i YEI) iz četiri programska razdoblja (1994.–1999., 2000.–2006., 2007.–2013. i 2014.–2020.), ljudski kapital, ukupna faktorska produktivnost i Indeks ekonomskih sloboda. Podaci su preuzeti iz baze ARDECO, Penn World Table (ljudski kapital i ukupna faktorska produktivnost) i baze podataka Fraserova instituta (Indeks ekonomskih sloboda).

Metode

Procjenjuje se sljedeći model s trostrukim interakcijskim članom:

$$g_{i,t} = \alpha_i + \rho_t + \beta_1 y_{i,t-\tau} + \beta_2 F_{it} + \beta_3 Q_{i,t} + +\lambda_1 y_{i,t-\tau} F_{it} + \lambda_2 y_{i,t-\tau} Q_{it} + \lambda_3 F_{it} Q_{it} + +\theta y_{i,t-\tau} F_{i,t} Q_{i,t} + \mu X_{it} + \varepsilon_{it} \quad (1)$$

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

Konvergencija se izražava kao:

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

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

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

Rezultati

U tablici 2 prikazani su rezultati procijenjenog modela sa trostrukim interakcijskim članom. Predznaci ispred varijabli stope rasta stanovništva, ljudskog kapitala i ukupne faktorske produktivnosti su u skladu sa teorijskim očekivanjima. Sve tri varijable su statistički značajne pri čemu stopa rasta stanovništva ima negativan utjecaj na stopu gospodarskog rasta, a ljudski kapital i ukupna faktorska produktivnost pozitivan. Suprotno od rezultata prikazanih u tablici 1, stopa zaposlenosti ima statistički značajan i negativan utjecaj na gospodarski rast, ali je magnituda utjecaja mala. Također, investicije nemaju statistički značajan utjecaj na gospodarski rast što nije očekivano s teorijskog stajališta niti je u skladu s rezultatima u tablici 1. To bi se moglo objasniti uvođenjem ukupnih izdataka iz EU fondova u model. Izdaci iz EU fondova imaju statistički značajan i pozitivan utjecaj na gospodarski rast što može upućivati na to da izdaci iz EU fondova djelomično obuhvaćaju i vezu investicija i stope rasta BDP-a, stoga varijabla investicija samostalno nema dodatnu eksplanatornu moć u modelu.

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

Tablica 2. Rezultati modela sa trostrukim interakcijskim članom

VARIJABLE	Stopa gospodarskog rasta
EU fondovi	71.69**
	(34.79)
BDPpc(t-5)	4.396
	(3.731)
IES	0.490
	(0.373)
EU fondovi × BDPpc(t-5)	-7.300**
	(3.580)
EU fondovi × IES	-0.714**
	(0.347)
BDPpc(t-5)× IES	-0.0456
	(0.0372)
EU fondovi × BDPpc(t-5)* IES	0.0727**
	(0.0357)
Investicije	1,122
	(1,052)
Stopa rasta stanovništva	-1.560**
	(0.612)
Ljudski kapital	0.188***
	(0.0357)

TFP	0.835***
	(0.153)
Stopa zaposlenosti	-0.00668***
	(0.00192)
Konstanta	-48.13
	(37.37)

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

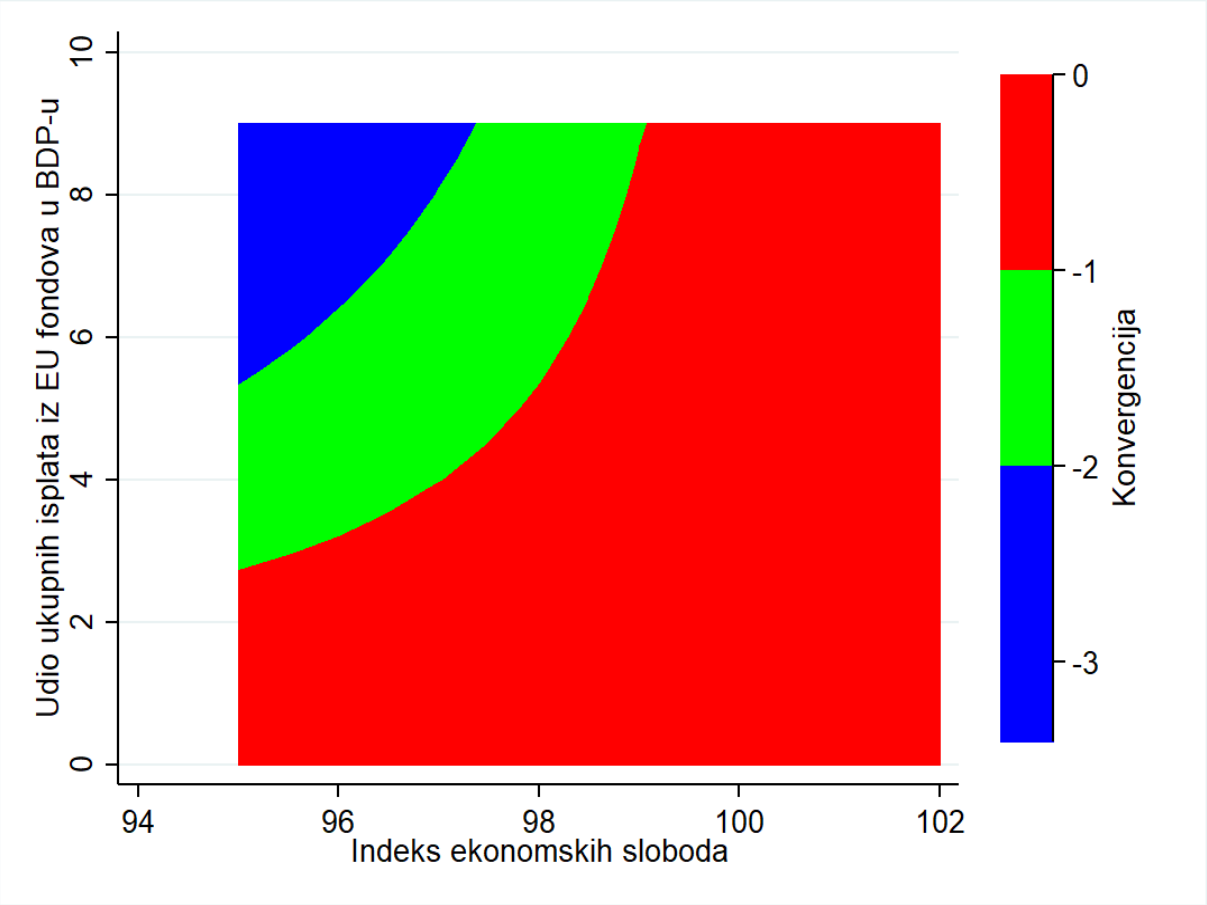
Na slici 3 prikazan je konturni grafikon s rezultatima utjecaja kombinacije ukupnih izdataka iz EU fondova i Indeksa ekonomskih sloboda na konvergenciju. Na x-osi je Indeks ekonomskih sloboda, a na y-osi udio ukupnih izdataka iz europskih strukturnih fondova u BDP-u regije. Boje označavaju jačinu konvergencije,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

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

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

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

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



Izvor: Markušić (2026)

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

Rezultati ovog istraživanja upućuju na to da kohezijska politika ostvaruje svoj konvergencijski cilj, ali i na to da brzina sustizanja sama po sebi nije dostatna mjera njezine uspješnosti. Manje razvijene regije primaju veće potpore jer je prihvatljivost vezana uz razinu BDP-a po stanovniku, a ne uz kvalitetu institucija; budući da su to u pravilu i regije slabije institucionalne kvalitete, one u promatranom

razdoblju konvergiraju brže. Ako pri tome raste i kvaliteta institucija, sustizanje se nastavlja i nakon smanjenja priljeva sredstava. Kako institucionalna kvaliteta raste, doprinos dodatnih sredstava iz EU fondova na konvergenciju slabi, pa se o održivoj konvergenciji može govoriti u mjeri u kojoj jačanje institucija istodobno podiže i ravnotežnu razinu dohotka. Glavno upozorenje koje iz toga slijedi jest da visoka apsorpcija i brzo sustizanje mogu se javiti zajedno sa slabim institucijama, pa je ključno pitanje pretvaraju li se potpore u trajni rast produktivnosti ili samo u privremeno produbljivanje kapitala. Ta se razlika u nastavku rada razrađuje kroz razlikovanje apsorpcijskog i konvergencijskog kapaciteta.

3. Razvojna zamka: Apsorpcijski nasuprot konvergencijskom kapacitetu

3.1 Definicija i konceptualna pojašnjenja

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

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

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

Mehanizmi koji objašnjavaju zamku siromaštva razlikuju se od mehanizama zamke srednjeg dohotka, dok su mehanizmi zamke srednjeg dohotka i razvojne zamke vrlo slični budući da je razvojna zamka izveden i prilagođen pojam, izravno inspiriran konceptom zamke srednjeg dohotka. Tu poveznicu prva

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

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

Ključno je uočiti da se radi o zamci, dakle o (lošem) ravnotežnom stanju koje nema tendenciju promjene bez značajne intervencije (Agénor, 2017). Zamka je dijametralno suprotna konceptu konvergencije, koji sugerira da dolazi do promjene, odnosno postupnog sustizanja među zemljama tijekom vremena. Kada se govori o regijama ili skupini zemalja poput EU, postojanje razvojne zamke najčešće sugerira postojanje višestrukih dugoročnih ravnoteža, što je usko povezano s konceptom klubova konvergencije. Naime, apsolutna konvergencija (među svim zemljama) implicira da će u dugom roku sve zemlje doseći istu razinu dohotka po glavi stanovnika ako imaju slične inicijalne uvjete. S druge strane, postojanje zamke, odnosno klubova konvergencije, sugerira da će zemlje u dugom roku doseći različite razine dohotka po glavi stanovnika te da će se razlike među njima zadržati, a potencijalno i produbiti.

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

U kontekstu regionalne razvojne zamke u EU najčešće se koristi relativna mjera razvijenosti u odnosu na europski prosjek. Diemer i sur. (2022) pri identifikaciji regija u razvojnoj zamci razlikuju regije prema inicijalnoj razini BDP-a per capita (u paritetu kupovne moći) relativno u odnosu na prosjek EU: regije s BDP-om per capita ispod 75 % prosjeka EU smatraju se nisko razvijenima, regije s udjelom

između 75 % i 100 % prosjeka srednje razvijenima, dok se regije iznad 100 % prosjeka smatraju visoko razvijenima. Autori pokazuju da je rizik ulaska u razvojnu zamku najizraženiji upravo među srednje razvijenim regijama, odnosno onima čiji je BDP per capita između 75% i 100% prosjeka EU, što je u skladu s hipotezom o razvojnoj zamci na razini srednjeg dohotka.

Nijedna metoda identifikacije zamke srednjeg dohotka nije bez kritika (Agénor, 2017). Apsolutne razine dohotka se često smatraju arbitrarnima te su Eichengreen i sur. (2014) pokazali da je distribucija zemalja koje upadaju u zamku srednjeg dohotka bimodalna, što znači da zemlje upadaju u zamku srednjeg dohotka pri različitim razinama dohotka. S druge strane, relativne mjere pate od problema paralelnog rasta referentne vrijednosti (benchmarka), odnosno gospodarskog rasta SAD-a u slučaju Catch-Up indeksa ili prosjeka EU u slučaju identificiranja regionalne razvojne zamke. Osobito u slučaju EU, uvijek će biti regija ili zemalja koje će biti ispod (ili iznad) prosjeka EU, bez obzira na to koliko je visok njihov životni standard.

3.2 Glavni uzroci nastanka zamke srednjeg dohotka

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

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

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

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

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

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

Diemer i sur. (2022) sistematiziraju karakteristike koje regije u razvojnoj zamci dijele sa zemljama u zamci srednjeg dohotka. Prvo, njihova je razina troškova previsoka da bi bile konkurentne u proizvodnji osnovnih dobara i usluga s manje razvijenim regijama unutar EU te sa zemljama niskog i nižeg srednjeg dohotka izvan granica EU. Drugo, razina vještina i inovacijskih kapaciteta je ispod one u regijama visokog dohotka EU, zbog čega nisu konkurentne u proizvodnji naprednih i tehnološki intenzivnih dobara i usluga. Treće, njihova je ekonomska stagnacija dodatno pojačana procesima premještanja proizvodnje u inozemstvo (engl. *offshoring*), kao i ograničenim kapacitetima za privlačenje izravnih stranih ulaganja i/ili za podupiranje internacionalizacije domaćih poduzeća. Rezultat su dugotrajna razdoblja stagnacije, iznadprosječne razine nezaposlenosti, posebice dugotrajne nezaposlenosti, te u pojedinim slučajevima i demografski pad. Takve regije stoga ostaju zarobljene u sredini: preskupe za konkurenciju troškovima, a nedovoljno inovativne za konkurenciju znanjem.

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

iz niskog u srednji dohodak, već se može pojaviti na različitim razinama dohotka, uključujući i prijelaz s više na srednju razinu dohotka.

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

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

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

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

Upravo tu logiku formalizira strategija 3i iz izvješća Svjetske banke (2024). Prema tom okviru, prikladna kombinacija razvojnih strategija ovisi o razvojnom statusu zemlje i odvija se u fazama. Zemlje niskog dohotka rastu prvenstveno kroz investicije, odnosno akumulaciju fizičkog kapitala i izgradnju osnovne infrastrukture. Na nižim srednjim razinama dohotka investicije nisu dovoljne te ih je potrebno upariti s infuzijom, odnosno s usvajanjem i difuzijom tehnologija koje već postoje na svjetskoj tehnološkoj granici, najčešće putem izravnih stranih ulaganja (engl. foreign direct investment - FDI) i uključivanja

u globalne vrijednosne lance. Tek na višim srednjim razinama dohotka presudna postaje treća komponenta, inovacija, odnosno pomicanje same tehnološke granice. Ključna poruka izvješća nije da su investicije nevažne, nego da je oslanjanje isključivo na prvu komponentu dugoročno neodrživo: zemlje zapadaju u zamku jer predugo ostaju u fazi 1i, umjesto da pravovremeno prijeđu na 2i i 3i. Za zemlje EU to je posebno relevantno, jer strukturni fondovi po svojoj konstrukciji financiraju upravo investicijsku fazu, pa je pitanje održivosti konvergencije pitanje pretvaraju li se ta ulaganja u infuziju i inovaciju ili ostaju puko produbljivanje kapitala.

Prijelaz između faza teorijski se najbolje objašnjava fenomenom kreativne destrukcije. Schumpeter (1942) rast promatra kao proces u kojem novi proizvodi, tehnologije i poduzeća istiskuju postojeće, pa je rast neodvojiv od realokacije resursa i destrukcije postojećih proizvoda i praksi. Aghion i Howitt (1992) taj su mehanizam formalizirali u modelu endogenog rasta u kojem inovacije proizlaze iz ulaganja u istraživanje i razvoj motiviranog privremenim monopolskim položajem, a nove inovacije potencijalno uništavaju prethodne. Rast tada ovisi o očekivanoj vrijednosti inovacije, dakle o zaštiti intelektualnog vlasništva, pristupu financiranju i izvršavanju ugovora, ali i o slobodi ulaska i izlaska poduzeća, jer bez izlaska neuspješnih nema realokacije. Acemoglu, Aghion i Zilibotti (2006) pokazuju da optimalna kombinacija politika ovisi o udaljenosti od tehnološke granice: aranžmani koji podupiru rast daleko od granice, poput zaštite velikih etabliranih proizvođača, postaju kočnica rasta kada rast zahtijeva selekciju i ulazak novih poduzeća. Aghion i Bircan (2017) na tome temelje schumpeterovsku interpretaciju zamke srednjeg dohotka kao neuspjeha prijelaza s imitacije na inovaciju. Akcigit i Kerr (2018) dodatno upozoravaju da nije važna samo količina, nego i sastav inovacija. Inkrementalne inovacije koje etablirani proizvođači provode na vlastitim proizvodima djeluju drukčije od radikalnih inovacija koje najčešće dolaze od novih poduzeća i koje su presudne za agregatni rast.

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

Rezultati konvergencijske analize iz prvog dijela rada s tim su okvirom u posrednom, ali informativnom odnosu. Procjene ne potvrđuju postojanje „zida“ u konvergenciji na razini od približno 80 % prosjeka

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

4. Računovodstvo rasta za analizu apsorpcijskog i konvergencijskog kapaciteta

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

4.1 Podaci

Dekompozicija se provodi za svih 27 zemalja članica EU, a rezultati se u ovom poglavlju fokusiraju na Hrvatsku i Portugal kao zemlju s iskustvom dugotrajnog zastoja u konvergenciji. Koriste se tri baze podataka jer nijedna sama ne pokriva sve što je potrebno. Penn World Table 11.0 (Feenstra, Inklaar i Timmer, 2015) daje najdužu vremensku seriju od 1950. do 2023. godine, te podatke o uslugama kapitala i indeks ljudskog kapitala. Za nove zemlje članice, uključujući Hrvatsku, podaci su dostupni od 1995. EU KLEMS & INTANProd, izdanje 2023. (Bontadini i sur., 2023), pokriva razdoblje od 1995. do 2021. godine i nudi najfiniju podjelu: kapital je razdvojen na materijalni ICT (engl. *Information and communication technologies*), materijalni bez ICT-a te nematerijalni, a doprinos rada na odrađene sate i na kvalitetu, odnosno sastav radne snage (ljudski kapital). Za Hrvatsku i većinu novih zemalja članica, ovako fina podjela je dostupna tek od 2009. To stvara određeni kompromis *(trade-off)* između dužine vremenske serije i dubine dekompozicije faktora rasta. Konačno, AMECO, proljetna verzija 2026. (Europska komisija, 2026), pokriva razdoblje od 1960. do 2027. godine, jedina ima istovjetnu definiciju za sve članice i jedina seže do razdoblja provedbe Mehanizma za oporavak i otpornost (u Hrvatskoj je to Nacionalni plan oporavka i otpornosti - NPOO), pri čemu su 2026. i 2027. prognoze pa se prikazuju odvojeno. Za Hrvatsku i većinu novih zemalja članica podaci su dostupni od 1995. godine.

4.2 Metode

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

$$\Delta ln\, Y_t = \underline{s_t} \Delta ln\, H_t + \left(1 - \underline{s_t}\right) \Delta ln\, K_t + \underline{s_t} \Delta ln\, hc_t + \Delta ln\, A_t \quad (3)$$

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

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

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

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

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

Rezultate treba čitati uz nekoliko ograda. TFP je rezidual, pa uz tehnološki napredak upija i pogrešku mjerenja, promjene u iskorištenosti kapaciteta i realokaciju resursa među sektorima, što je u recesijskim godinama posebno izraženo. Ponderiranje udjelima u dohotku pretpostavlja konstantne prinose na opseg i konkurentna tržišta faktora, što su jake pretpostavke. AMECO uz to koristi neto zalihu kapitala umjesto

usluga kapitala, pa je doprinos kapitala iz te baze sustavno podcijenjen, a konvergencijska košarica (ljudski kapital i TFP) precijenjena.

4.3 Rezultati

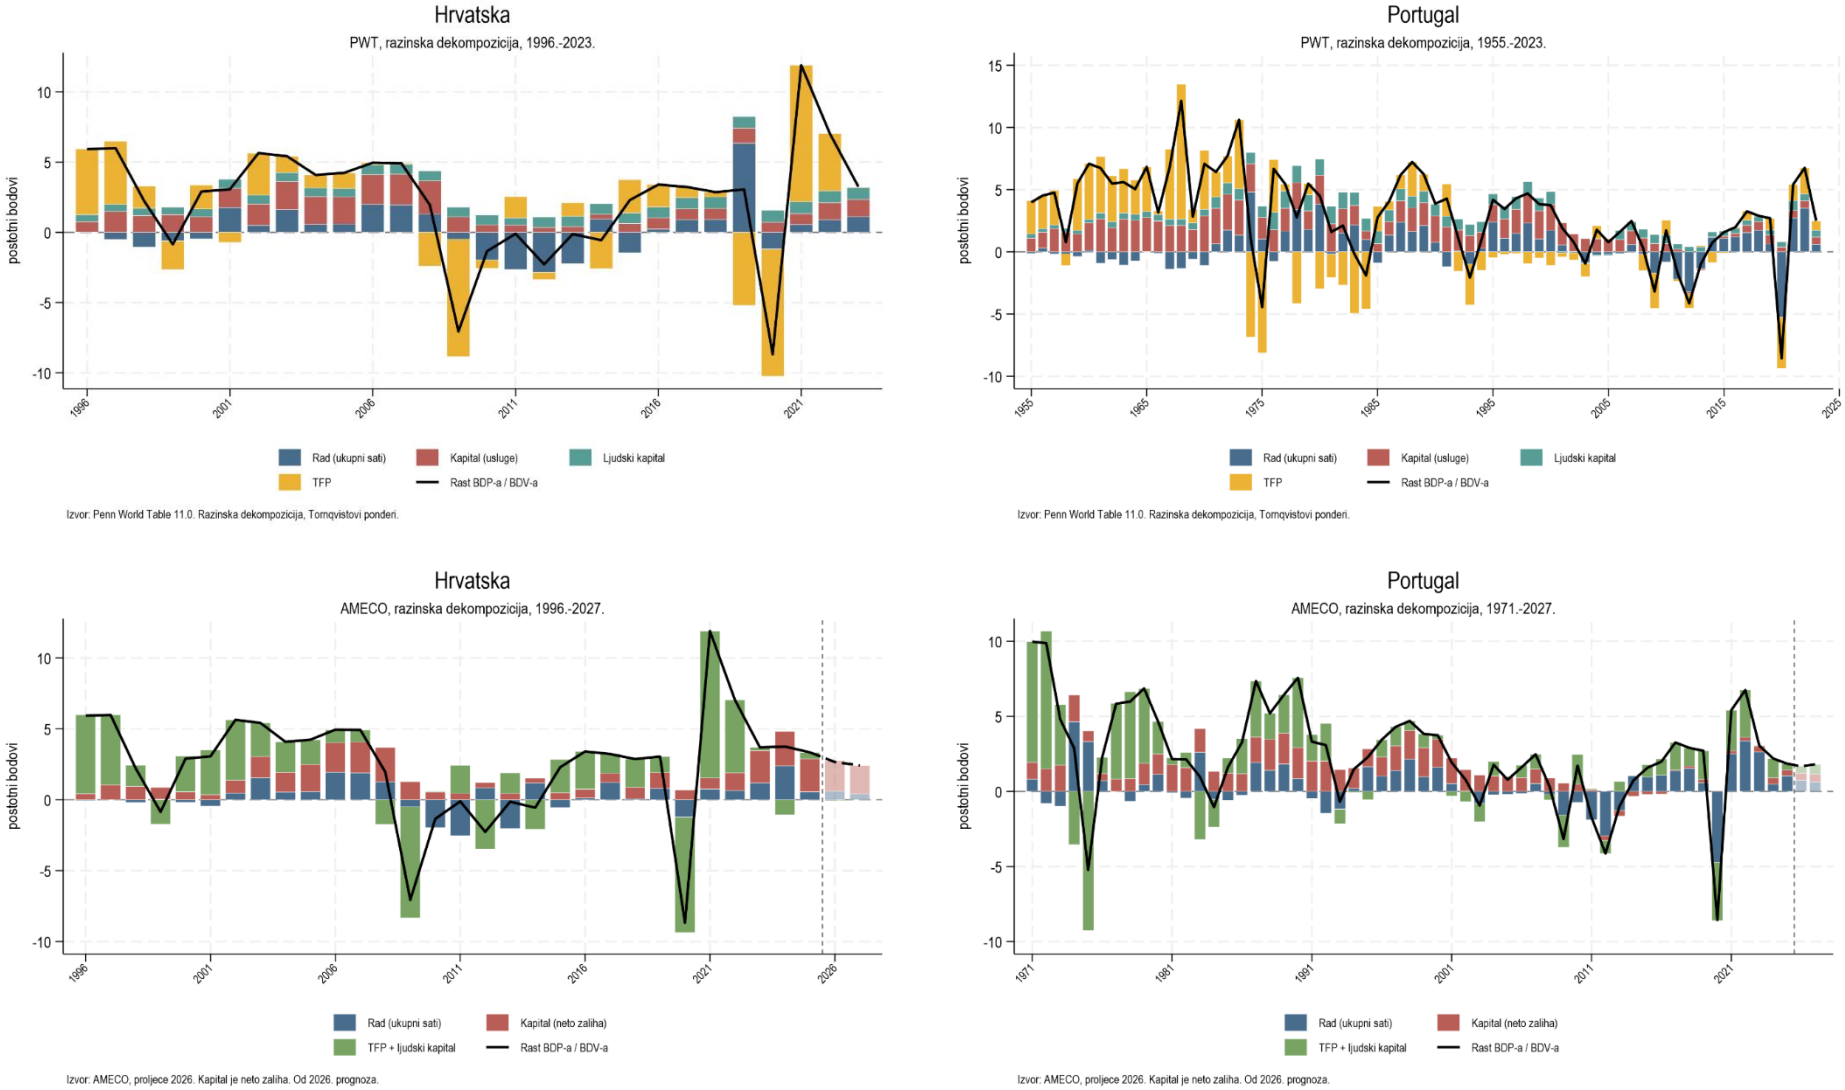
U nastavku su prikazani rezultati računovodstva rasta. Analiza je provedena za sve zemlje EU, ali se u radu fokusiramo na Hrvatsku i Portugal. Naime, Portugal je odabran kao zemlja za koju se često navodi da se nalazi u zamci srednjeg dohotka ili razvojnoj zamci, jer nakon što je prvotno bio iznad 90 % prosjeka EU po veličini BDP-a per capita, došlo je do relativnog pada i već duže vrijeme ne uspijeva probiti granicu od 80 %, što je prikazano na slici 2.

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

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

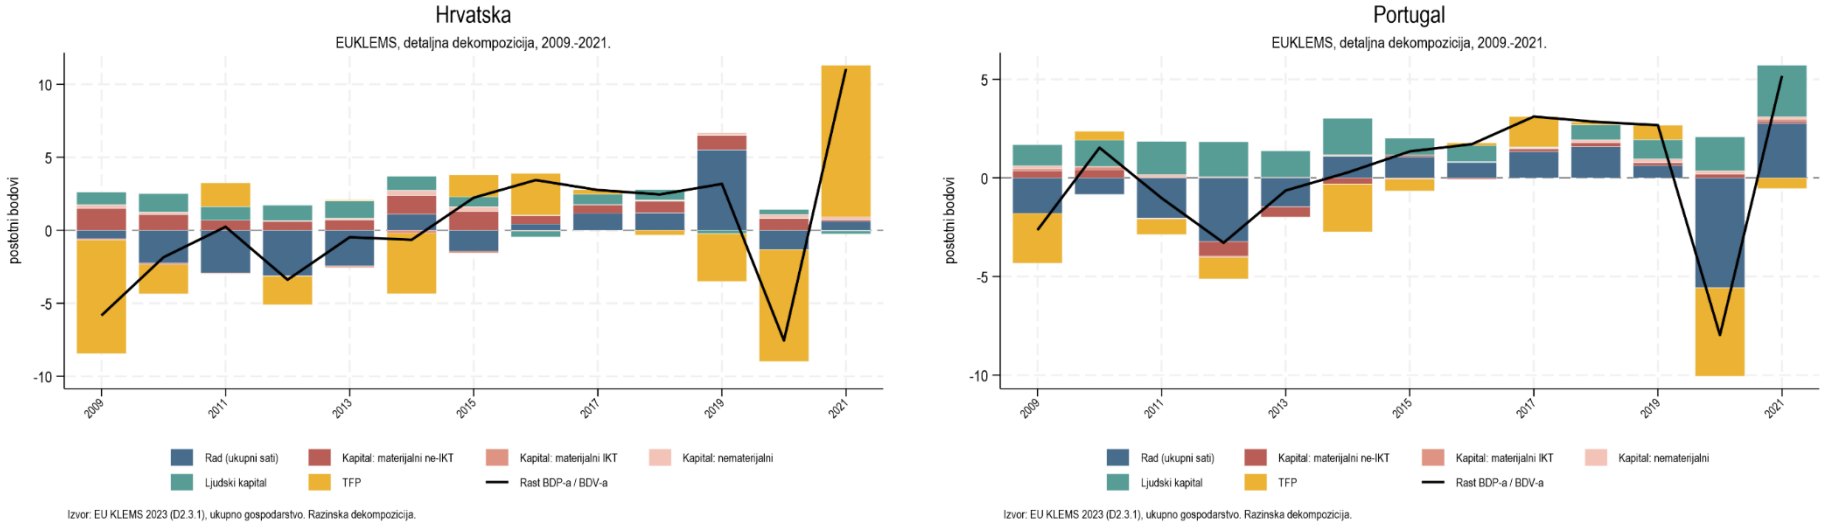
U 2019. godini zabilježen je skok prosječnog broja odrađenih sati po zaposlenome u bazama Penn World Table i EU KLEMS, s 1811 na 1996 sati godišnje (oko 10 %), pri čemu se nova razina zadržava i u kasnijim godinama. Malo je vjerojatno da je riječ o stvarnoj promjeni radnog vremena, već se prije radi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

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



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

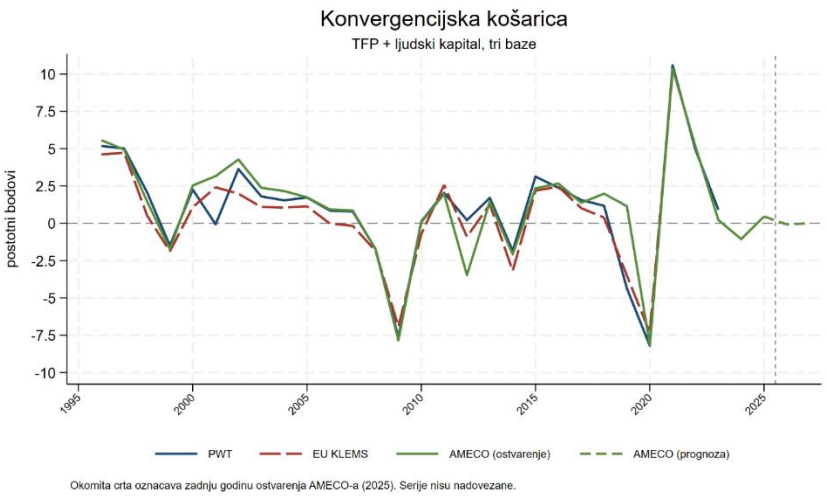
Slika 4. (nastavak) Računovodstvo rasta: dekompozicija rasta BDP-a prema tri baze podataka



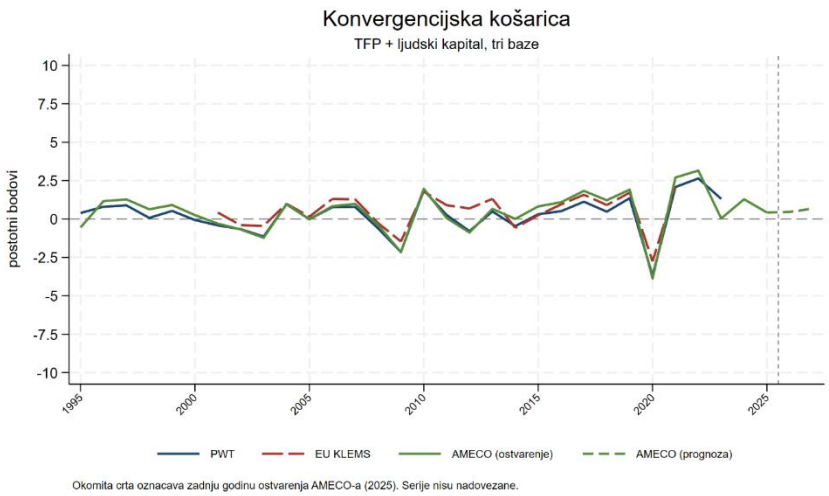
Izvor: Penn World Table 11.0, AMECO (proljeće 2026.) i EU KLEMS 2023 (D2.3.1); izračun autora.

Slika 5. Konvergencijska košarica nasuprot doprinosu kapitala rastu

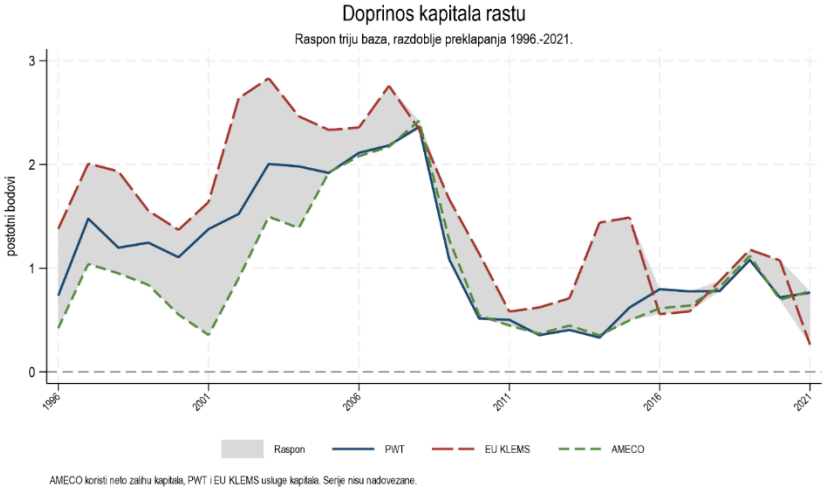
Hrvatska



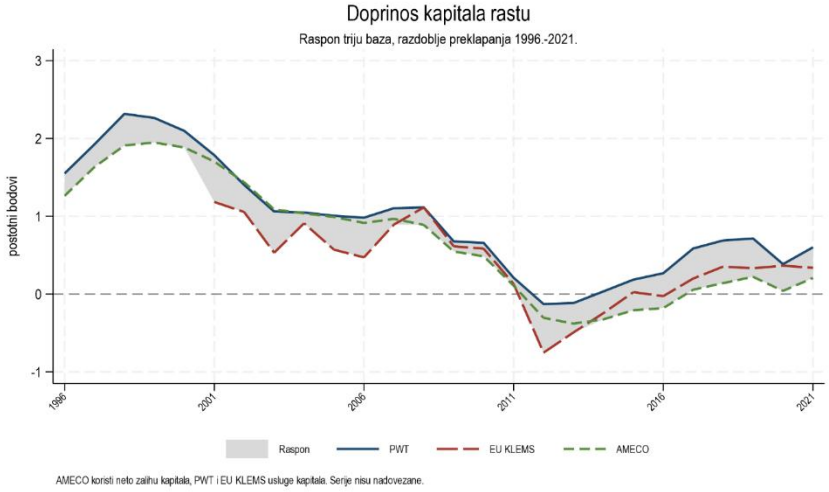
Portugal



Hrvatska



Portugal



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

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

U ukupnom promatranom razdoblju, Portugal ima drugi najveći doprinos ljudskog kapitala u EU, 0,51 postotni bod (najveći doprinos ima Hrvatska od 0,70), uz vrlo nizak doprinos ukupne faktorske produktivnosti od −0,25 postotnih bodova. Riječ je dakle o zemlji koja je uspješno provela fazu infuzije, izgradila ljudski kapital i usvojila postojeće tehnologije, ali nije napravila prijelaz u fazu inovacije, dakle zapela je na drugom prijelazu prema strategiji 3i. To je konzistentno sa schumpeterovskim tumačenjem zamke srednjeg dohotka kao neuspjeha prijelaza s imitacije na inovaciju (Aghion i Bircan, 2017) i objašnjava zašto portugalsko iskustvo ne predstavlja upozorenje samo zemljama na nižim razinama razvoja.

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

Naposljetku, rezultati računovodstva rasta temeljem EU KLEMS baze podataka usklađeni su s dosadašnjim zaključcima za Hrvatsku, naglašavajući utjecaj TFP-a u 2021. godini (treći redak Slike 4). Godina 2019. i ovdje predstavlja izdvojenicu (*outlier*) zbog prekida u seriji radnih sati. Doprinos fizičkog kapitala i svih njegovih podvrsta (ICT kapital, kapital koji ne uključuje ICT te nematerijalni kapital) je konstantno pozitivan, kao što je i očekivano, ali ima relativno skroman doprinos rastu.

Najveći problem ove baze je kratak obuhvat pune dekompozicije od 2009. do 2021. U slučaju Portugala vidljiv je nešto snažniji utjecaj ljudskog kapitala na rast, ali ponovno ograničen utjecaj TFP-a.

Slika 5 usporedno prikazuje konvergencijsku košaricu izračunatu prema sve tri baze podataka za Hrvatsku i Portugal (gornji dio slike) koja se sastoji od zbroja TFP-a i ljudskog kapitala. Donji dio Slike 5 usporedno prikazuje doprinos kapitala rastu za iste dvije zemlje prema sve tri baze podataka. Vidljivo je da su mjere konvergencijske košarice iz sve tri baze podataka vrlo usklađene i govore o gotovo identičnoj dinamici. S druge strane, zbog različitih definicija kapitala među bazama, prikazani su različiti rasponi utjecaja kapitala na ekonomski rast, pri čemu je očekivano AMECO najniži, jer mjeri samo neto zalihu kapitala umjesto usluga kapitala.

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

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

Naposljetku, identična analiza je provedena i za preostalih 25 zemalja članica EU. Rezultati za sve zemlje su sumarno prikazani u Prilogu A u Tablici A2. Radi jednostavnosti, tablica prikazuje rezultate samo za PWT bazu podataka, premda su rezultati za ostale baze usporedivi i usklađeni. Iz Tablice A2 vidljivo je da su zemlje s najbržim rastom u promatranom razdoblju ujedno ostvarile i najveći konvergencijski kapacitet. To se prije svega odnosi na baltičke zemlje, gdje konvergencijska košarica iznosi 2,71 postotni bod u Latviji, 2,19 u Litvi i 2,04 u Estoniji, zatim na Slovačku s 1,90, Irsku s 1,58 te Poljsku i Rumunjsku s 1,49 postotnih bodova. Hrvatska pripada skupini brzorastućih zemalja po stopi rasta BDP-a, koja iznosi 2,41 posto godišnje, ali ne i po konvergencijskom kapacitetu, gdje s 1,01 postotnim bodom zauzima jedanaesto mjesto među 27 članica, iza svih navedenih zemalja i uz vrijednost jednaku malteškoj. Hrvatski doprinos ukupne faktorske produktivnosti od 0,31 postotnog

boda zauzima petnaesto mjesto i ispod je prosjeka novih članica koji iznosi jedan postotni bod. Struktura hrvatskog rasta u promatranom razdoblju stoga je bliža prosjeku EU nego skupini usporedivih posttranzicijskih zemalja.

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

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

4.4 Utjecaj isplata iz EU fondova na TFP i konvergencijski kapacitet

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

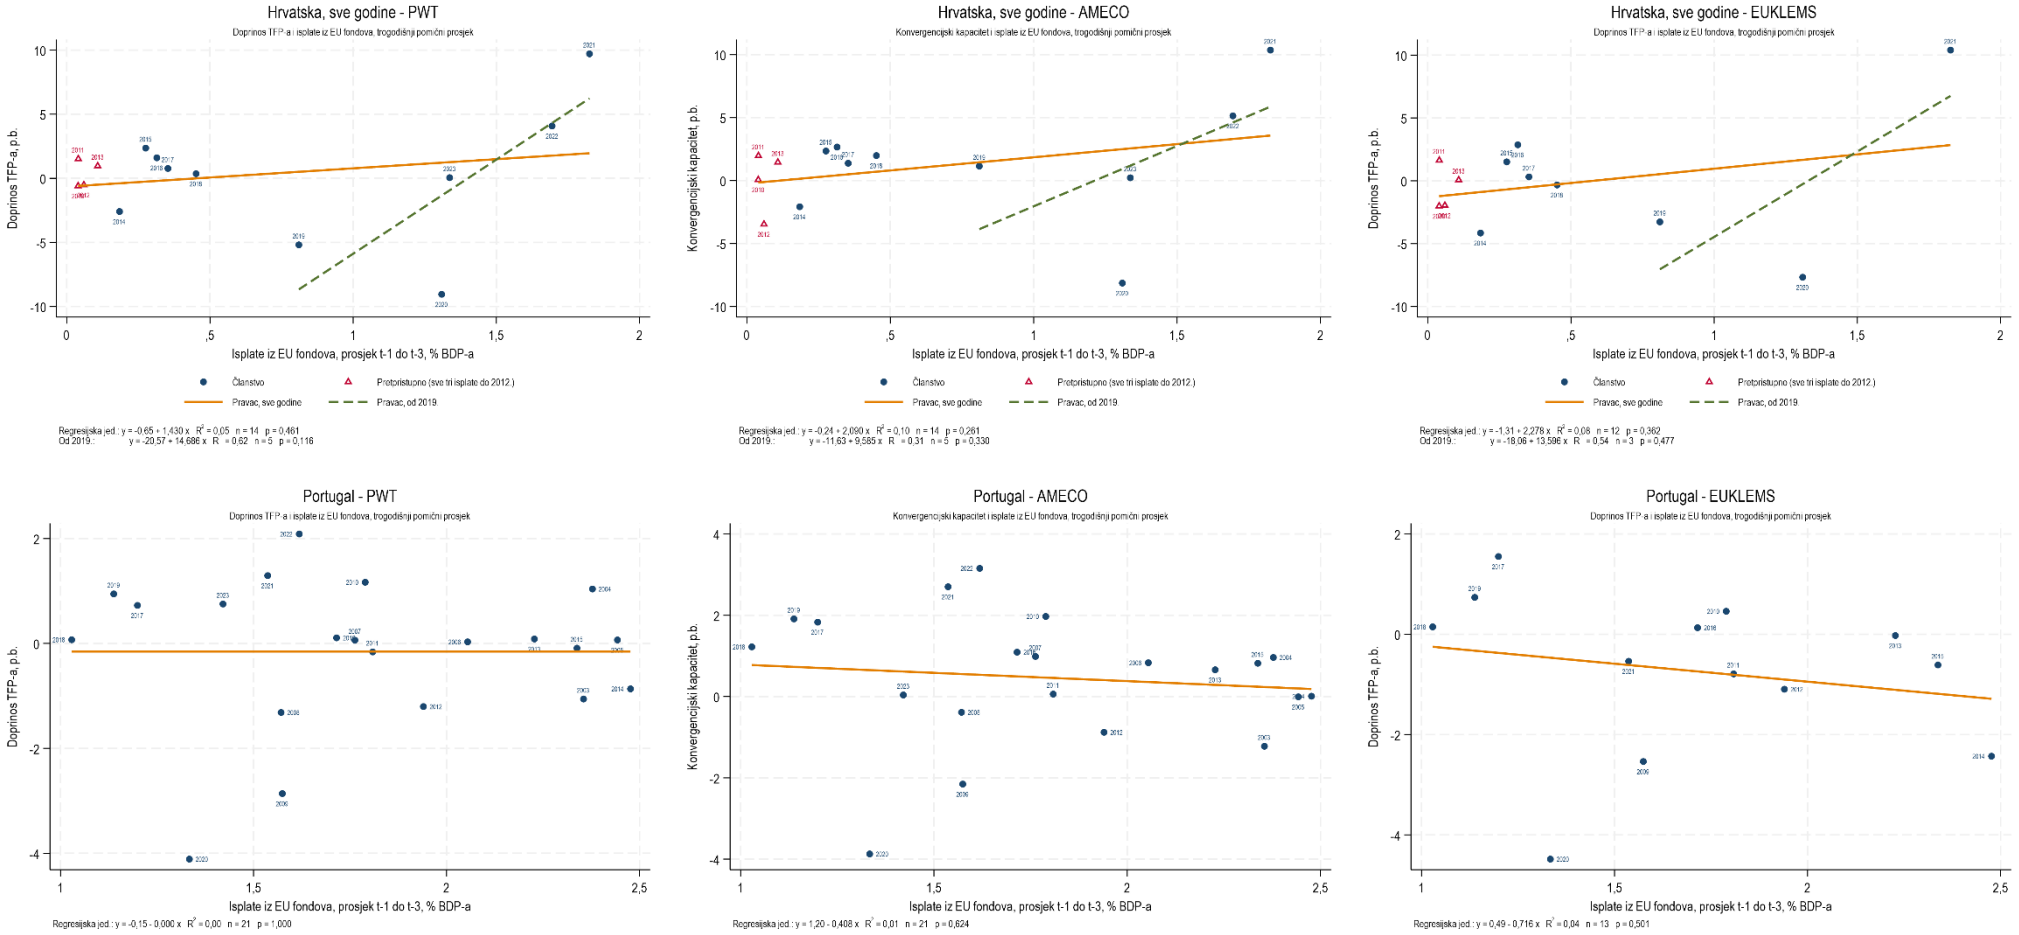
Pozitivna veza isplata iz EU fondova i TFP-a bi značila da se sredstva iz EU fondova pretaču u produktivnost i inovacije koje potom utječu na tekući i budući gospodarski rast. Sredstva iz EU fondova tada bi bila dobro iskorištena. Negativna veza bi značila da se sredstva iz EU fondova ulažu u druge faktore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

Prije same analize, potrebno je istaknuti nekoliko ograničenja. Prvo, nisu svi EU fondovi usmjereni na gospodarski rast niti na rast TFP-a. Najbolji primjeri takvih programa su fondovi Garancija za mlade,

Europski socijalni fond[4] ili Fond europske pomoći za najpotrebitije. Najbliži je tom cilju Europski fond za regionalni razvoj, premda ni kod tog fonda nisu sva sredstva izravno povezana s rastom BDP-a niti TFP-a. U radu promatramo sve fondove agregatno, ali rezultati su robusni kada se u analizi promatra samo udio sredstava iz Europskog fonda za regionalni razvoj. Drugo, prava kauzalna analiza za Hrvatsku i Portugal bi trebala uzeti u obzir kontrolne varijable, duže vremensko razdoblje i sofisticiranije metode utvrđivanja kauzalnosti. Međutim, u ovome radu se neformalno promatra povezanost korištenjem jednostavnih grafikona rasipanja. Treće, analiza je ograničena na razdoblje od 2007. do 2022. za Hrvatsku i od 2000. do 2022. za Portugal, što je prilično kratko razdoblje, ali je uvjetovano dostupnošću podataka.

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

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



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

Neformalna analiza pomoću grafikona rasipanja prikazana je na Slici 6. Prvi redak prikazuje rezultate za Hrvatsku za sve tri baze, dok drugi redak prikazuje rezultate za Portugal. Rezultati za AMECO bazu prikazuju konvergencijski kapacitet umjesto TFP-a. Puna narančasta linija prikazuje smjer veze za sve promatrane godine u slučaju obiju zemalja. Iscrtkana zelena linija za Hrvatsku prikazuje vezu za razdoblje od 2019. do zadnje dostupne godine (2022. za PWT i AMECO baze te 2021. za EU KLEMS bazu). Pretpristupne godine za Hrvatsku, od 2007. do 2012., posebno su prikazane trokutićima. Isplate iz EU fondova su prikazane s vremenskim pomakom od jedne godine te predstavljaju trogodišnje prosjeke. Ispod svakog grafikona je prikazana regresijska jednadžba koja opisuje nacrtani pravac zajedno s R-kvadratnom vrijednosti (R^2), brojem promatranja (n) i p-vrijednosti koeficijenta uz nagib regresijskog pravca.

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

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

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

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

5. Zaključak

5.1 Temeljni zaključci rada

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

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

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

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

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

Veza između sredstava iz EU fondova i ukupne faktorske produktivnosti nije čvrsta u slučaju Hrvatske i Portugala. Međutim, rezultati sugeriraju kako je regresijski pravac u slučaju Hrvatske blago pozitivnog

nagiba, uz osobito snažan pozitivan nagib za razdoblje od 2019. do 2022. S druge strane, regresijski pravac u slučaju Portugala je blago negativnog nagiba, što sugerira dodatne razlike među zemljama. Stoga, moguće je da je u Hrvatskoj dio sredstava iz EU fondova našao put do djelatnosti koje povećavaju produktivnost i konvergencijski kapacitet.

5.2 Preporuke za ekonomsku politiku

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

Predlažemo da se uz stopu iskorištenosti EU sredstava uvede i redovito prati konvergencijska košarica, definirana kao zbroj doprinosa ljudskog kapitala i ukupne faktorske produktivnosti rastu bruto domaćeg proizvoda. Riječ je o pokazatelju koji se izračunava iz javno dostupnih podataka nacionalnih računa, metodologijom prikazanom u ovom radu, i koji se može objavljivati godišnje uz izvješća o provedbi operativnih programa. Takav pokazatelj odgovara na pitanje koje stopa iskorištenosti ne može odgovoriti: pretvaraju li se povučena sredstva u sposobnost gospodarstva da raste i nakon što priljev prestane. Pri tumačenju treba imati na umu da je ukupna faktorska produktivnost rezidual koji upija i promjene u iskorištenosti kapaciteta, pa pokazatelj treba promatrati u višegodišnjem prosjeku i ciklički prilagođeno, a ne kao godišnju ocjenu.

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

Na europskoj razini rezultati upućuju na ograničenje sadašnjih kriterija prihvatljivosti. Pragovi od 75 posto prosjeka za status slabije razvijene regije i 90 posto bruto nacionalnog dohotka za korištenje Kohezijskog fonda definirani su isključivo razinom dohotka. Naši rezultati pokazuju da se pokretači rasta mijenjaju s razvojnim statusom: ljudski kapital i ukupna faktorska produktivnost statistički su

značajni samo u poduzorku zemalja iznad 80 posto prosjeka Unije, dok ispod tog praga značajne ostaju samo investicije. Iz logike strategije 3i slijedi da bi se s razvojnim statusom trebala mijenjati i struktura instrumenata, a ne samo intenzitet potpore.

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

Nalaz da Hrvatska ima najveći doprinos ljudskog kapitala rastu u Uniji uz osrednji doprinos produktivnosti mijenja prioritete obrazovne i inovacijske politike. Ograničenje nije u razini obrazovanosti radne snage, nego u tome gdje ta radna snaga završava. Literatura o zamci srednjeg dohotka taj mehanizam opisuje kao pogrešnu distribuciju ljudskog kapitala, pri čemu sposobni pojedinci biraju sektore s višim ili sigurnijim plaćama umjesto rizičnih poduzetničkih i inovacijskih djelatnosti, a razlozi su slaba zaštita intelektualnog vlasništva, neizvjesno izvršavanje ugovora i ograničen pristup financiranju putem rizičnog kapitala (Agénor i Canuto, 2015; Agénor, 2017).

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

5.3 Ograničenja i preporuke za buduća istraživanja

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

zemalja članica, te sektorska dekompozicija kojom bi se izravno testirala hipoteza o preusmjeravanju kapitala prema nerazmjenjivim djelatnostima.

PRILOG A. Dodatni rezultati

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

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

	1996-2023	1.42	0.24	0.91	0.51	-0.25	0.26	1.16
EUKLEMS	2001-2007	1.22	-0.05	0.80			0.47	0.75
	2008-2013	-0.90	-1.59	0.20			0.49	-1.39
	2014-2018	1.86	1.18	0.06	0.86	-0.24	0.62	1.24
	2020-2021	-1.40	-1.40	0.35	2.17	-2.51	-0.34	-1.05
	2001-2021	0.59	-0.30	0.39			0.50	0.09
AMECO	1996-2007	2.37	0.57	1.40			0.40	1.97
	2008-2013	-1.33	-1.43	0.22			-0.12	-1.21
	2014-2018	2.09	1.20	-0.10			1.00	1.10
	2020-2023	1.66	0.94	0.22			0.51	1.16
	1996-2025	1.48	0.34	0.65			0.49	0.99
	2022-2025	3.46	1.88	0.36			1.23	2.24
	2026-2027*	1.74	0.68	0.49			0.57	1.17

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

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

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

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

Napomena: Sve vrijednosti u postotnim bodovima.

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

LITERATURA

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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