PRILOG 1
MAKROEKONOMSKO MODELIRANJE ZA NDC3.0 U BOSNI I HERCEGOVINI

Sadržaj

1. UVOD I PRISTUP 3
2. PRISTUPI MAKROEKONOMSKOM MODELIRANJU I NJIHOVA PRIMJENJIVOST NA NDC3.0 U BIH 3
3. DOSTUPNOST I KVALITET PODATAKA TE OGRANIČENJA MODELIRANJA 6
4. MAKROEKONOMSKA I NDC POLAZNA OSNOVA ZA BIH 7
4.1. Makroekonomska dinamika ključnih pokazatelja tokom posljednje dvije decenije 7
4.2. Energetska tranzicija i trendovi emisija 12
4.3. Institucionalno okruženje 14
4.4. Preliminarni odnosi između NDC i makroekonomskih varijabli 14
5. MAKROEKONOMSKO MODELIRANJE I EMPIRIJSKI ODNOSI ZA NDC3.0 U BIH 16
5.1. Uvod 16
5.2. Konceptualni okvir i kanali transmisije 16
5.3. Ekonometrijski pristup makroekonomskom modeliranju 18
5.4. NDC model rasta za BiH 19
5.5. NDC model emisija za BiH 22
5.6. Stabilnost procijenjenih NDC modela 25
6. ZAKLJUČCI, PREPORUKE I NAREDNI KORACI 26
7. REFERENCE 28
Spisak slika 30
Spisak tabela 30
Prilog – Tabela s opisom varijabli u NDC skupu podataka 31

1. UVOD I PRISTUP

Makroekonomsko modeliranje pruža sistematičan okvir za ispitivanje načina na koji se promjene ekonomskih uslova, politika i vanjskih faktora (posmatrane kroz različite makroekonomske pokazatelje) prenose kroz privredu i kako te promjene utiču na ključne makroekonomske outpute kao što su ekonomski rast, investicije, zaposlenost, javne finansije i međunarodna trgovina. Kvantificiranjem odnosa između ključnih ekonomskih agregata, makroekonomski modeli mogu podržati formulisanje politika, pružiti dokaze o mogućim kompromisima i komplementarnostima između različitih ciljeva politika te uspostaviti osnovu za ocjenu vjerovatnih posljedica alternativnih intervencija.

Značaj makroekonomskog modeliranja sve se više prepoznaje u kontekstu klimatske politike te pripreme i provedbe Nacionalno utvrđenih doprinosa (NDC). Mjere usmjerene na smanjenje emisija stakleničkih plinova i ubrzavanje tranzicije prema niskougljičnoj ekonomiji nisu izolovane okolišne intervencije. Ulaganja u obnovljivu energiju, poboljšanja energijske efikasnosti, promjene u strukturi proizvodnje i potrošnje energije, tehnološko unapređenje i pripadajuće regulatorne reforme mogu proizvesti šire efekte na ekonomsku aktivnost, zaposlenost, investicije i konkurentnost. I obrnuto, tempo i struktura ekonomskog rasta utiču na potražnju za energijom i pojačavaju emisije, a time utiču i na izvodljivost postizanja klimatskih ciljeva. Makroekonomsko modeliranje stoga može pružiti analitičku vezu između klimatskih i energetskih politika s jedne strane i razvojnih ekonomskih ciljeva s druge strane.

Za Bosnu i Hercegovinu (BiH) ova vrsta sistematične makroekonomske procjene do sada nije bila integrisana u NDC dokumente. Analiza razvijena u ovom poglavlju stoga predstavlja početni pokušaj uspostavljanja empirijski utemeljenog okvira makroekonomskog modeliranja koji može podržati NDC3.0. Njegov dizajn ciljano je vođen dostupnošću, kvalitetom i vremenskim obuhvatom podataka u BiH. Umjesto primjene složenog okvira modeliranja čije informacione zahtjeve postojeći podaci ne mogu adekvatno podržati, pristup nastoji identifikovati realističan skup makroekonomskih, energetskih, emisionih i institucionalnih varijabli za koje postoje dovoljno konzistentne historijske informacije te istražiti interakcijske odnose među njima.

Ostatak poglavlja organizovan je kako slijedi. Prvi dio daje pregled glavnih pristupa makroeknomskom modeliranju i razmatra njihovu primjenjivost na NDC3.0 u Bosni i Hercegovini. Drugi dio ispituje dostupnost i kvalitet potrebnih podataka i identifikuje glavna metodološka ograničenja modeliranja. Treći dio uspostavlja makroekonomsku i NDC polaznu osnovu analizom historijskih makroekonomskih, energetskih, emisionih i institucionalnih trendova i njihovih preliminarnih odnosa. Četvrti dio razvija početni okvir makroekonomskog modeliranja, uključujući njegove konceptualne kanale transmisije, ekonometrijski pristup te preliminarne modele makroekonomskog rasta i emisija. Posljednji dio sumira glavne nalaze.

2. PRISTUPI MAKROEKONOMSKOM MODELIRANJU I NJIHOVA PRIMJENJIVOST NA NDC3.0 U BIH

Makroekonomska procjena NDC mjera može se provesti korištenjem nekoliko vrsta alata i modela, ovisno o svrsi analize, dostupnosti podataka, institucionalnim kapacitetima, ekonomskoj razvijenosti i vremenskom okviru. Iako se lista čini prilično dugom, razmatramo nekoliko najrelevantnijih za kontekst BiH, koja je postkonfliktna i tranzicijska ekonomija suočena s još uvijek ograničenim statističkim kapacitetima i s tim povezanim nedostacima podataka, posebno na disagregiranim nivoima analize.

Međunarodna praksa makroekonomske procjene za potrebe NDC modeliranja često se zasniva na pristupima kao što su modeli opće ravnoteže, alati za procjenu klimatskih politika, input-output modeli, modeli matrice društvenog računovodstva, makroekonometrijski modeli, sektorski energetsko-ekonomski modeli i hibridni alati zasnovani na heterogenim scenarijima. Iako su to metodologije koje se mogu koristiti u različitim kontekstima, svrha kao i ograničenja podataka faktori su koji će u konačnici odrediti izbor metodologije.

Modeli opće ravnoteže (CGE) napredni su modeli koji omogućavaju procjenu interakcija na nivou cijele privrede, uključujući i promjene cijena, efekte supstitucije, fiskalne mjere i distributivne uticaje. Međutim, oni zahtijevaju detaljne i konzistentne skupove podataka, uključujući sve ulazne podatke za matricu društvenog računovodstva (SAM), bihevioralne parametre i specijalizovane kapacitete za modeliranje. Za zemlje s ograničenom statističkom infrastrukturom ili kratkim rokovima pripreme, CGE modele je teško izvodljivo razviti od nule. Ipak, takav model korišten je u nedavnoj studiji OECD-a (2025) koja obuhvata uzorak zemalja Zapadnog Balkana. Procjena za BiH pri tome nije bila zasnovana na autentičnim podacima prikupljenim u ovoj zemlji, nego na regionalnim ulaznim podacima („podaci za ostatak Evrope“) prilagođenim i kalibriranim za BiH. Štaviše, ovaj model koristi statičke parametre zasnovane na podacima za jednu godinu iz prethodne decenije, što možda ne obuhvata u potpunosti naknadne strukturne promjene u ekonomiji BiH, energetskom sistemu i okruženju politika u novijem periodu. Očigledno, CGE pruža korisnu aproksimaciju za analizu politika, ali istovremeno uvodi neizvjesnost i rezerve u pogledu dobijenih rezultata. Stoga, za potrebe savremene pripreme NDC 3.0, jednostavniji pristupi mogu predstavljati transparentniju i izvodljiviju kratkoročnu opciju modeliranja, dok bi se namjenski CGE okvir mogao razviti kao dugoročni institucionalni cilj u budućnosti.

Drugi pristup modeliranju je *Alat za procjenu klimatske politike* (CPAT), koji je razvio Međunarodni monetarni fond (MMF) u saradnji sa Svjetskom bankom i drugim partnerima, a primijenili su ga, na primjer, Beck et al. (2023). CPAT predstavlja okvir za simulaciju klimatskih politika, a ne potpuni model izračunljive opće ravnoteže (CGE). On integriše modeliranje potražnje za energijom, obračun emisija stakleničkih plinova, fiskalnu analizu i procjenu makroekonomskih uticaja radi ocjene mjera ublažavanja, uključujući određivanje cijene ugljika, reformu subvencija za fosilna goriva, uvođenje obnovljive energije i javne investicije povezane s klimom. Međutim, CPAT i dalje zahtijeva konzistentne informacije na nivou sektora (npr. za različite industrije) o potrošnji energije, emisijama, cijenama, tehnološkim pretpostavkama, fiskalnim parametrima i makroekonomskim pokazateljima, što za BiH podrazumijeva dodatnu pripremu i harmonizaciju podataka. Stoga, iako bi CPAT mogao pružiti korisne uvide za procjenu NDC politika, njegova primjena za sveobuhvatno makroekonomsko modeliranje u BiH tokom planiranog perioda NDC modeliranja ograničena je dostupnošću dovoljno disagregiranih i validiranih nacionalnih skupova podataka. On bi mogao predstavljati praktičnu buduću opciju modeliranja kada se sektorske baze podataka i institucionalni kapaciteti za modeliranje dalje razviju.

Input–output (IO) i *modeli zasnovani na matrici društvenog računovodstva (SAM)* se često primjenjuju kada je cilj procijeniti ekonomske uticaje klimatskih politika i investicija na proizvodnju, dodanu vrijednost, zaposlenost i trgovinu. Input–output modeli obuhvataju međusektorske odnose unutar privrede i procjenjuju kako promjene u finalnoj agregatnoj potražnji, kao što su investicije povezane s klimom ili promjene u potražnji za energijom, generišu direktne i indirektne efekte među sektorima kroz mehanizme kratkoročnog multiplikatora (Miller i Blair, 2009). Multiplikatori objašnjavaju kako promjena bilo koje vrste potrošnje u jednoj makroekonomiji dovodi do multiplikativnih efekata na ekonomske ishode, poput agregatne proizvodnje i BDP-a, kroz naredne krugove stvaranja dohotka i potrošnje (Keynes, 1936; Blanchard, 2021). Multiplikatorski modeli zasnovani na SAM-u proširuju input–output okvir uključivanjem transakcija između proizvodnih sektora, faktora proizvodnje, domaćinstava, države i vanjskih računa, čime omogućavaju širu procjenu uticaja strukturnih zaokreta politika na proizvodnju, raspodjelu dohotka, zaposlenost i trgovinske tokove (Breisinger et al., 2009). U poređenju sa složenijim pristupima na nivou cijele privrede, kao što su CGE modeli, IO i SAM modeli mogu se primijeniti uz umjerene zahtjeve modeliranja, ali im i dalje trebaju konzistentni sektorski računi te podaci o zaposlenosti, trgovini i input–output odnosima. BiH trenutno nema u potpunosti razvijen i redovno ažuriran skup sektorskih računa potrebnih za sveobuhvatno IO ili SAM modeliranje; međutim, davanje prioriteta prikupljanju i harmonizaciji detaljnih podataka za ključne sektore relevantne za klimu moglo bi predstavljati važan prvi korak ka razvoju takvih analitičkih kapaciteta u budućnosti.

Sektorski energetski alati kao što su sistem *Long-range Energy Alternatives Planning* (LEAP), *Integrated MARKAL System* (TIMES) i *Market Allocation* (MARKAL) koriste se za razvoj scenarija ublažavanja, analizu transformacija energetskog sistema i procjenu putanja smanjenja emisija stakleničkih plinova. LEAP (Low Emissions Analysis Platform) je alat za modeliranje energije zasnovan na scenarijima koji ocjenjuje alternativne putanje energije i emisija povezujući potražnju za energijom, procese transformacije i uticaje na okoliš. Razvio ga je Stockholmski institut za okoliš i organizovan je kroz on-line platformu s odgovarajućim vodičima (Heaps, 2022). TIMES/MARKAL modeli su tehnološki

bogati, bottom-up optimizacijski modeli energetskog sistema koji identifikuju energetske putanje najnižeg troška predstavljajući energetske tehnologije, raspoloživost resursa, investicione izbore i operativna ograničenja tokom vremena (Loulou i sar., 2016). Međutim, iako ovi modeli pružaju detaljne uvide u tranzicije energetskog sektora, oni obično ne procjenjuju šire makroekonomske efekte kao što su uticaji na BDP, zaposlenost, javne prihode, dohodak domaćinstava ili trgovinu, osim ako nisu povezani s makroekonomskim modelima kao što su CGE, input–output/SAM ili makroekonometrijski okviri. Ne smatramo ih korisnim za modeliranje u NDC-u BiH, a uz to su i zahtjevni u pogledu podataka na sektorskom nivou te, kako je gore opisano, trenutno nisu izvodljivi.

Makroekonometrijski modeli koriste se za procjenu agregatnih ekonomskih efekata politika i vanjskih šokova na varijable kao što su BDP, zaposlenost, investicije, inflacija, javni prihodi i vanjski bilansi. Ovi modeli koriste historijske podatke vremenskih serija i standardne ekonometrijske tehnike, kao što su metod najmanjih kvadrata (OLS), vektorska autoregresija (VAR), modeli korekcije greške (ECM) i autoregresijski modeli s distribuiranim pomacima (ARDL), kako bi procijenili odnose između ekonomskih varijabli i ocijenili kratkoročne i dugoročne efekte promjena politika. U poređenju s CGE modelima, makroekonometrijski modeli obično zahtijevaju manje strukturnih pretpostavki, ali njihova pouzdanost ovisi o dostupnosti dovoljno dugih i konzistentnih historijskih skupova podataka. Standardne ekonometrijske metode korištene u ovim modelima, uključujući regresijsku analizu, modeliranje vremenskih serija i dinamičke specifikacije, opširno se razmatraju u ekonometrijskoj literaturi (Wooldridge, 2020) i mogu se primijeniti na makroekonomski skup podataka BiH koji je relevantan za NDC modeliranje, uključujući njihovu primjenu za aproksimaciju multiplikativnih efekata (Blanchard, 2021). Njihovo glavno ograničenje jeste to što zahtijevaju duge i konzistentne historijske vremenske serije, koje možda nisu uvijek dostupne u dovoljnom okviru za modeliranje klimatskih politika. U kontekstu BiH, dostupnost dovoljno dugih i harmonizovanih historijskih skupova podataka i dalje predstavlja izazov, posebno za detaljne pokazatelje povezane s klimatskim promjenama. Međutim, sve veća dužina i kvalitet makroekonomskih vremenskih serija čine makroekonometrijske pristupe izvodljivom opcijom za NDC modeliranje. Stoga bi priprema NDC 3.0 mogla predstavljati važan korak ka razvoju okvira modeliranja zasnovanog na dokazima primjenom raspoloživih podataka i ekonometrijskih metoda u mjeri koja je trenutno realna.

Konačno, *Hibridni okvir makroekonomske procjene* čini se korisnim pristupom tamo gdje dostupnost podataka i institucionalni kapaciteti ograničavaju primjenu potpuno razvijenih CGE, IO ili SAM modela. Hibridni pristup podrazumijeva korištenje različitih ili kombinovanih tehnika modeliranja za procjenu makroekonomskih politika u kontekstu cijele privrede (OECD, 2024). Takav pristup kombinuje perspektive modeliranja (npr. bottom-up i top-down, Hourcade et al., 2006) s makroekonometrijskim modelima, raspoloživim sektorskim informacijama, koeficijentima zaposlenosti, fiskalnim parametrima, proračunima trgovinskog bilansa, pa čak i elementima input–output ili SAM analize tamo gdje podaci to dopuštaju. Time hibridni okviri povezuju klimatske politike i investicije s ključnim ekonomskim kanalima transmisije, uključujući formiranje kapitala, zaposlenost, energijsku efikasnost, trgovinsku konkurentnost i uticaje na javne finansije. Ovaj pristup je transparentan i fleksibilan unutar realnih ograničenja podataka i vremena, uz istovremeno omogućavanje buduće nadogradnje prema detaljnijim sektorskim ili CGE okvirima modeliranja (OECD, 2024). Stoga hibridni okvir usredsređen na makroekonometrijsko modeliranje predstavlja potencijalan pristup za pripremu NDC 3.0 u BiH.

Zaključno, konačan izbor pristupa modeliranju u kontekstu BiH u velikoj je mjeri vođen podacima zbog ograničenih skupova podataka koji su na raspolaganju. Na osnovu trenutne dostupnosti podataka i potreba modeliranja, u kombinaciji će se koristiti *makroekonometrijski modeli* i deskriptivni *hibridni okvir makroekonomske procjene* . Takvi pristupi mogu pružiti transparentne i za politike relevantne procjene makroekonomskih uticaja NDC mjera, uz istovremeno omogućavanje buduće nadogradnje prema detaljnijim IO/SAM ili CGE okvirima modeliranja kako se nacionalni skupovi podataka i kapaciteti za modeliranje budu poboljšavali.

3. DOSTUPNOST I KVALITET PODATAKA TE OGRANIČENJA MODELIRANJA

Pouzdano makroekonomsko modeliranje zahtijeva dovoljno konzistentne i uporedive podatke s adekvatnim vremenskim obuhvatom. Za NDC3.0 to podrazumijeva kombinovanje makroekonomskih pokazatelja s podacima o energiji, emisijama i institucijama iz različitih izvora. Osnovni makroekonomski pokazatelji za BiH dostupni su iz domaćih i međunarodnih izvora.

Za potrebe ove analize razvijena je integrisana godišnja NDC baza vremenskih serija koja kombinuje makroekonomske pokazatelje, pokazatelje tržišta rada, energije, emisija i institucija. Svjetski razvojni indikatori (WDI) Svjetske banke pružaju glavne serije koje koristimo, uključujući realni BDP, investicije, obnovljivu energiju i energijski intenzitet. Podaci o fondu kapitala preuzeti su iz Penn World Table, dok su podaci o zaposlenosti prvenstveno preuzeti od Agencije za statistiku BiH. World Economic Outlook (WEO) MMF-a[1][2][3] i ILOSTAT pružaju dopunske makroekonomske pokazatelje i indikatore tržišta rada prikupljene u NDC bazi podataka.[4]

Podaci o emisijama preuzeti su od Svjetske banke i iz dostupne baze o emisijama za globalna atmosferska istraživanja (EDGAR) Evropske komisije [5]. Institucionalni pokazatelji preuzeti su iz Svjetskih pokazatelja upravljanja (WGI) Svjetske banke [6], uključujući efikasnost vlade, kvalitet regulative, političku stabilnost, vladavinu prava i kontrolu korupcije. Zajedno, ovi izvori čine bazu podataka korištenu za deskriptivnu analizu i naknadno modeliranje makroekonomskog rasta i emisija u kasnijoj fazi. Detaljnije informacije o svim pokazateljima koji su korišteni ili razmatrani, a nisu uključeni u konačne modele, dostupne su u Prilogu 1.

Baza podataka konstruisana je do najdužeg zajedničkog perioda za koji se može sastaviti dovoljno širok skup pokazatelja, a obuhvata razdoblje 2000–2024. Obuhvat je najjači za glavne makroekonomske varijable kao što su BDP, bruto investicije u fiksni kapital, zaposlenost, izvoz i uvoz, koje daju kompletne godišnje serije u ovom periodu. Time se uspostavlja relativno konzistentna makroekonomska polazna osnova u odnosu na koju se mogu ispitivati kretanja u energiji, emisijama i institucionalnim uslovima.

Obuhvat je nešto ograničeniji za nekoliko varijabli koje su posebno relevantne za NDC modeliranje. Serija indikatora za praćenje obnovljive energije ne pokriva cijeli period, dok podaci o energijskom intenzitetu također nisu dostupni za sve godine. Većina WGI institucionalnih pokazatelja ima gotovo potpun, godišnji obuhvat. Podaci o javnim investicijama dostupni su za kraći period, što ograničava njihovo direktno uključivanje u modele koji koriste puni uzorak, ali će biti korišteni u analizi stabilnosti dobivenih rezultata. Ove razlike smanjuju efektivan broj opservacija kada je nekoliko varijabli uključeno istovremeno u model, a posebno su važne s obzirom na relativno kratku godišnju vremensku dimenziju baze podataka.

Nekoliko ograničenja sužava mogućnosti makroekonomskog modeliranja za NDC3.0 u BiH. Prvo, ne postoji uspostavljen nacionalni makroekonomski model posebno osmišljen za procjenu ekonomskih efekata klimatskih politika. Prethodne NDC procjene oslanjale su se prvenstveno na narativnu i deskriptivnu analizu. Predmetni modelski pristup stoga predstavlja početni pokušaj uspostavljanja takvog okvira i stoga mora ostati usklađena s raspoloživim podacima i nacionalnim kapacitetima za modeliranje.

---

[1] Svjetska banka, Svjetski razvojni indikatori (WDI): https://datatopics.worldbank.org/world-development-indicators/

[2] https://www.rug.nl/ggdc/productivity/pwt/?lang=en

[3] Međunarodni monetarni fond, baza podataka World Economic Outlook (WEO): https://data.imf.org/Datasets/WEO

[4] Međunarodna organizacija rada, ILOSTAT: https://ilostat.ilo.org/data/

[5] Evropska komisija, Zajednički istraživački centar, Baza podataka o emisijama za globalna atmosferska istraživanja (EDGAR): https://data.jrc.ec.europa.eu/collection/EDGAR

[6] Svjetska banka, Svjetski pokazatelji upravljanja (WGI): https://www.worldbank.org/en/publication/worldwide-governance-indicators

Detaljni i redovno ažurirani input–output podaci ili matrica društvenog računovodstva (SAM) nisu dostupni u obliku pogodnom za NDC modeliranje. To ograničava neposrednu primjenu pristupa na nivou cijele privrede koji zahtijevaju više podataka, kao što su CGE modeli, i ide u prilog korištenju agregatnog makroekonomskog modeliranja kao izvodljivije polazne tačke.

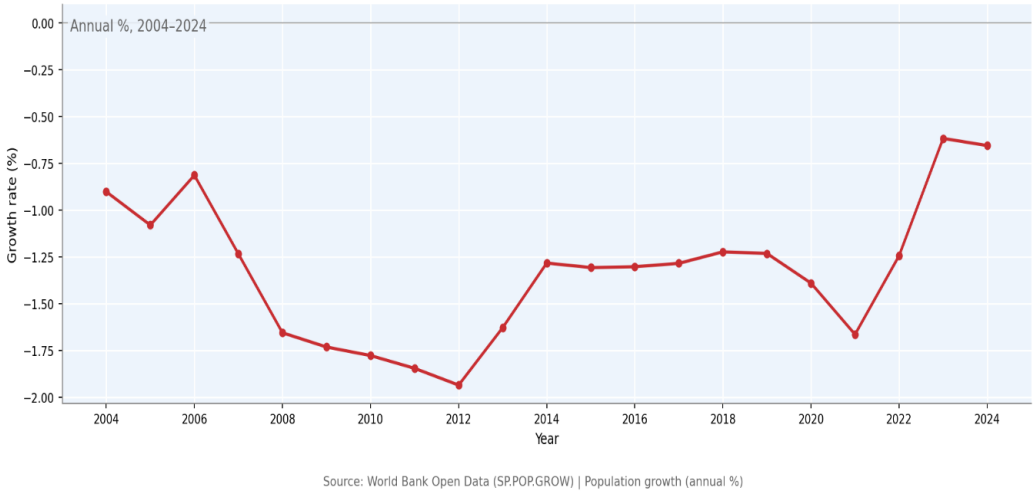
Raspoložive vremenske serije također nameću ekonometrijska ograničenja. Baza podataka obuhvata najviše 25 godišnjih opservacija (2000–2024). Osim toga, značajna neprijavljena ekonomija u BiH, u ranijim istraživanjima procijenjena na oko jednu trećinu BDP-a (Pasović i Efendić, 2018), unosi potencijalnu neizvjesnost za korištene indikatore, a koja se ne može u potpunosti otkloniti korištenjem raspoloživih zvaničnih pokazatelja.

4. MAKROEKONOMSKA I NDC POLAZNA OSNOVA ZA BIH

4.1. Makroekonomska dinamika ključnih pokazatelja tokom posljednje dvije decenije

Makroekonomsko okruženje predstavlja osnovu za procjenu potencijalnih ekonomskih implikacija mjera NDC3.0 u BiH i daje važne ulazne informacije za makroekonomski hibridni pristup modeliranju. Tokom posljednje dvije decenije, privreda je bilježila umjeren rast, poboljšanje parametara na tržištu rada kao i šire promjene u pokazateljima investicija, energije, trgovine i institucija. Ova kretanja uspostavljaju makroekonomsku polaznu osnovu za procjenu načina na koji investicije povezane s klimom i adekvatne mjere ublažavanja mogu djelovati na širu privredu. Rasprava stoga obuhvata širi skup relevantnih makroekonomskih pokazatelja, uključujući i neke koji nisu zadržani u konačnim specifikacijama modela, kako bi se pružilo sveobuhvatnije razumijevanje ekonomskog konteksta u kojem će se provoditi mjere NDC3.0 u BiH.

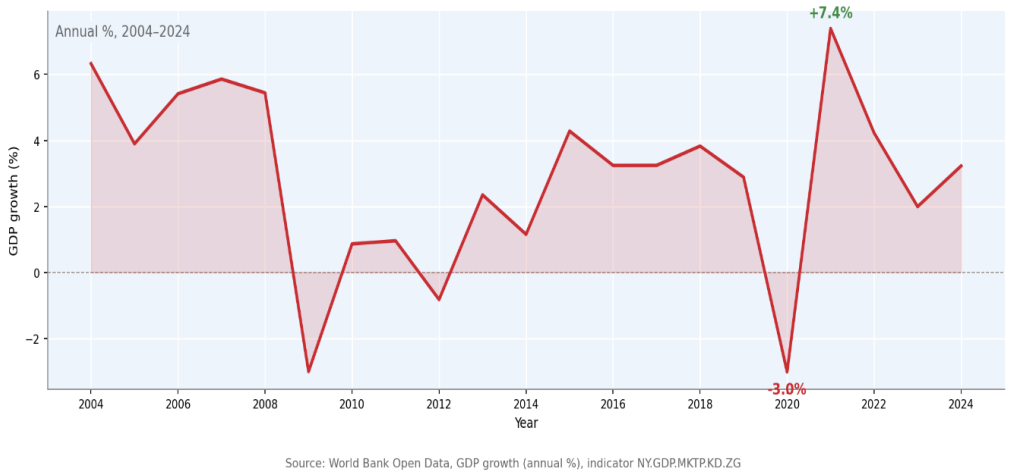
Pad broja stanovnika predstavlja važno strukturno ograničenje u BiH. Rast stanovništva ostao je negativan tokom cijelog posmatranog perioda, s posebno izraženim padovima u razdoblju 2008–2012. i 2020–2021, nakon čega je uslijedilo ublažavanje posljednjih par godina. Nastavak pada broja stanovnika može uticati na ponudu radne snage, domaću potražnju te raspoloživost radnika i vještina potrebnih za podršku investicijama i zelenoj tranziciji. Buduće projekcije trebaju imati ovu demografsku dinamiku u projekcijama.



Slika 1. Rast stanovništva (godišnji %)u BiH, 2004-2024

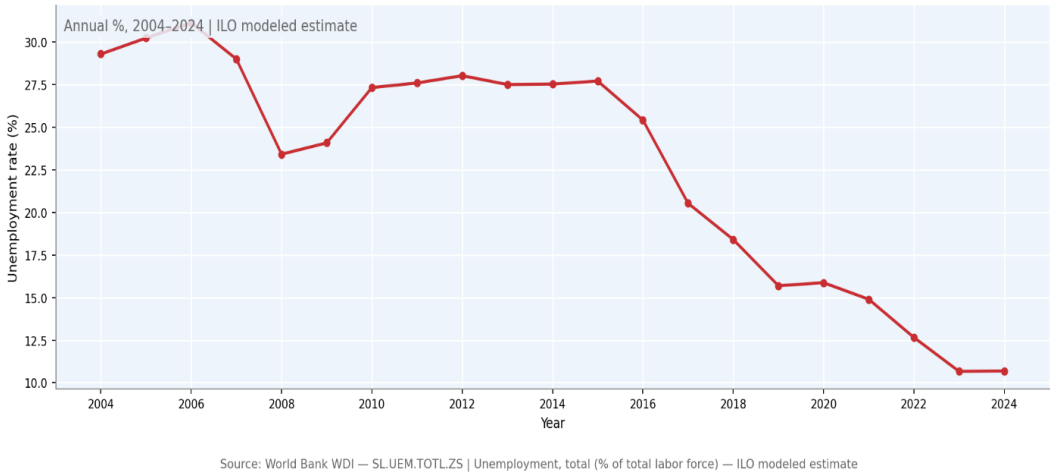
Ekonomski rast u BiH bio je pozitivan tokom većeg dijela posmatranog perioda, ali i podložan oscilacijama. Nakon snažnog rasta prije globalne finansijske krize uslijedila je kontrakcija od oko 3% u 2009. godini i još jedan manji pad u 2012. godini. Nastavio je period relativno stabilnog pozitivnog rasta

prije nego što je šok izazvan pandemijom COVID-19 doveo do nove kontrakcije privrede od približno 3% u 2020. godini. Naknadni oporavak bio je snažan, pri čemu je rast BDP-a dosegao 7,4% u 2021. godini, da bi se narednih godina ponovo usporio. Ovaj obrazac naglašava kako sposobnost privrede da se oporavi od velikih šokova, tako i njenu osjetljivost na promjenjive vanjske uslove, što treba uzeti u obzir pri procjeni budućih makroekonomskih efekata mjera NDC3.0. Posebno, ovo naglašava snažne kratkoročne oscilacije koje prate unutrašnje i vanjske cikluse.



Slika 2. Rast BDP-a (godišnji %) u BiH, 2004-2024

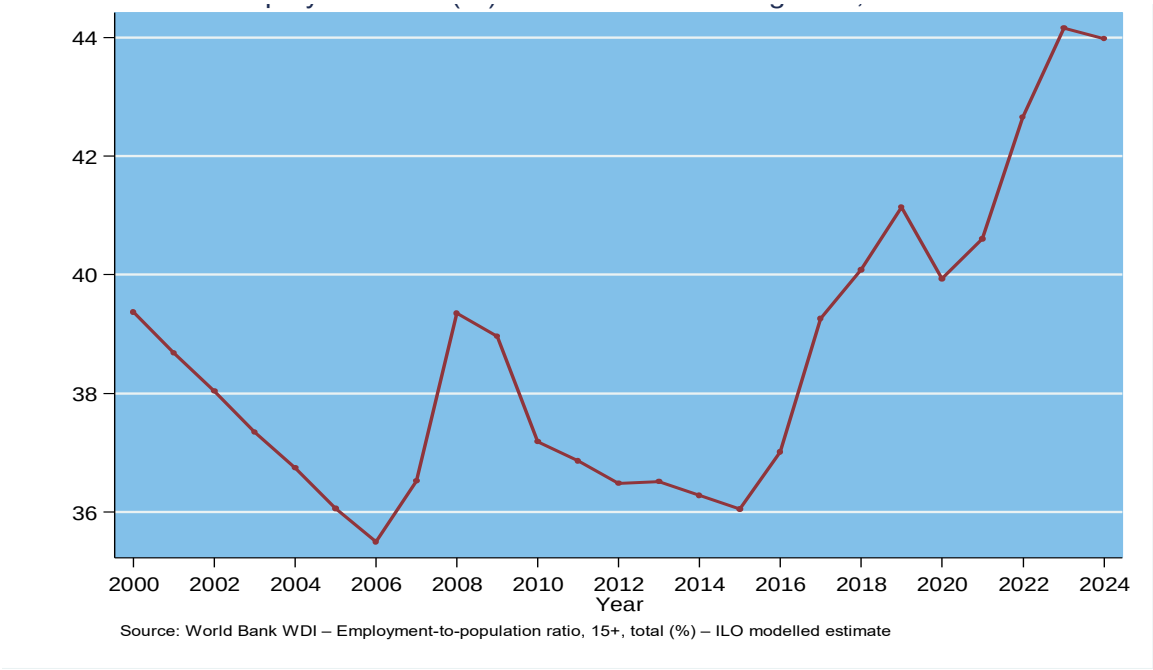
Rezultati tržišta rada zabilježili su poboljšanje tokom posljednje decenije koju posmatramo. Nezaposlenost je ostala izuzetno visoka tokom većeg dijela 2000-ih i početka 2010-ih godina, uglavnom prelazeći jednu četvrtinu radne snage, prije nego što je počela trajno opadati nakon sredine prošle decenije (Slika 2). Do 2023–2024. stopa nezaposlenosti pala je na oko 11%, znatno ispod ranijih nivoa. Uprkos ovom poboljšanju, ograničenja na tržištu rada ostaju važna u kontekstu pada broja stanovnika i aktuelnih migracija. Za NDC3.0 su, stoga, efekti investicija povezanih s klimom na zaposlenost relevantni ne samo u pogledu broja potencijalno stvorenih radnih mjesta, nego i u vezi s raspoloživošću odgovarajuće radne snage i vještina. Čini se da je strukturna nezaposlenost novi fenomen ekonomije BiH koji motiviše uvoz strane radne snage u pojedinim sektorima privrede.



Slika 3. Nezaposlenost, ukupno (% ukupne radne snage) u BiH, 2004-2024

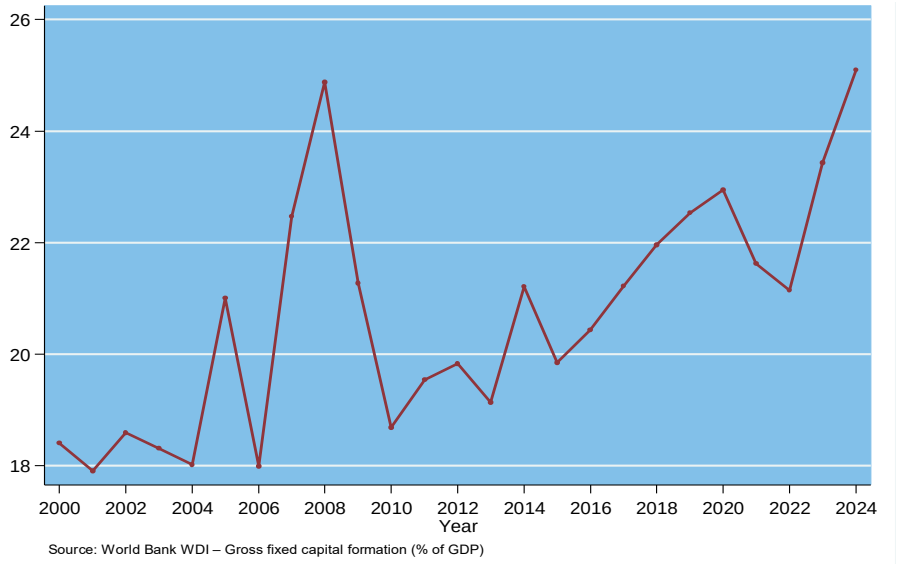
Kretanja u zaposlenosti u osnovi potvrđuju poboljšanje uočeno kod pokazatelja nezaposlenosti (Slika 4). Stopa zaposlenosti opadala je tokom prvog dijela perioda, dosegnuvši najniži nivo od oko 35,5% u 2006. godini, i ostala relativno niska tokom većeg dijela naredne decenije. Izraženije poboljšanje pojavilo se nakon 2015. godine, pri čemu je stopa zaposlenosti porasla iznad 44% do 2023–2024. Ovo

poboljšanje vidljivo je i u broju zaposlenih osoba prema domaćim statističkim izvorima, koji je posebno snažno rastao tokom kasnijeg perioda, dosegnuvši oko 850.000 u 2023. godini (ASBiH, 2026). Sveukupno, posljednju deceniju karakterizira jasan uzlazni trend zaposlenosti, uprkos privremenom poremećaju povezanom s pandemijom COVID-19. Ovo kretanje posebno je relevantno za okvir makroekonomskog modeliranja, u kojem zaposlenost predstavlja ključni ulazni faktor rada kroz koji se investicije i strukturna transformacija mogu pretočiti u veću ekonomsku aktivnost.



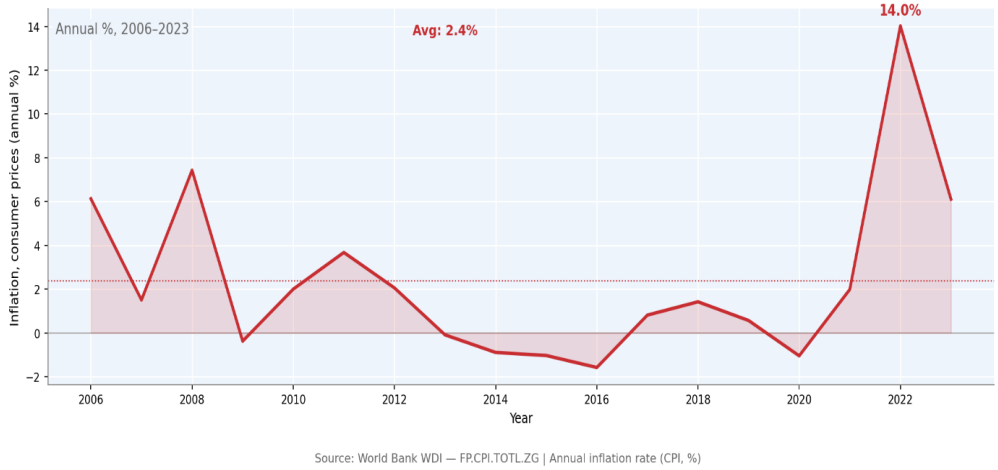
Slika 4. Stopa zaposlenosti (%) u BiH, 2000-2024

Bruto investicije u fiksni kapital (GFCF), koje odražavaju nivo investicione aktivnosti (Slika 5), pokazuju znatne oscilacije, ali i ukupno jačanje tokom posmatranog perioda. Investicije su tokom većeg dijela 2000-ih i početka 2010-ih uglavnom iznosile oko 18–21% BDP-a, prije trajnijeg povećanja nakon sredine prošle decenije, dosegnuvši približno 25% BDP-a u 2024. godini. Ova investiciona aktivnost doprinijela je znatnom proširenju proizvodne kapitalne osnove. Prema Penn World Table, procijenjeni realni fond kapitala BiH povećala se s približno 45 milijardi USD (oko 74 milijarde KM) na početku perioda na oko 186 milijardi USD (oko 307 milijardi KM) u 2023. godini, mjereno u stalnim cijenama iz 2021. godine. Ova razlika je važna za okvir NDC3.0 modeliranja.



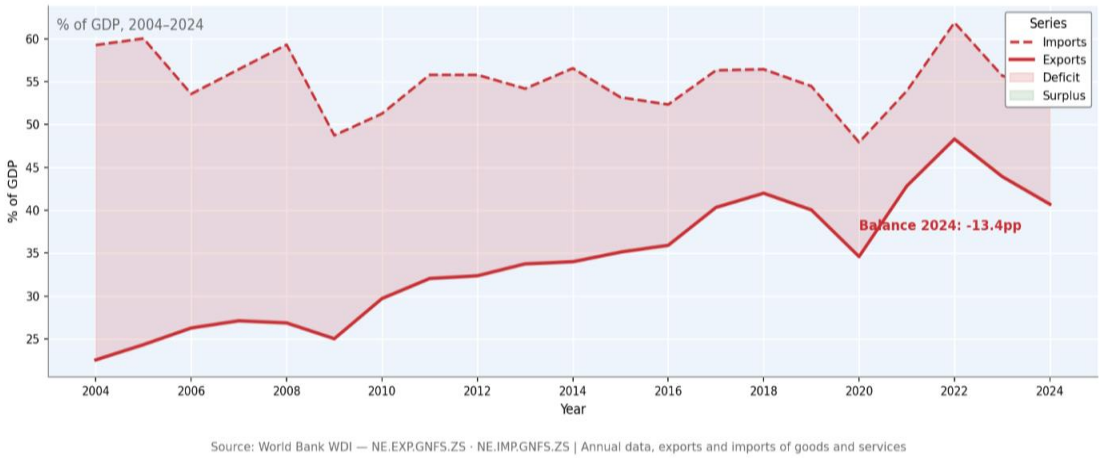
Slika 5. Bruto investicije u fiksni kapital (% BDP-a) u BiH, 2000-2024

Inflacija u Bosni i Hercegovini bila je relativno umjerena tokom većeg dijela prikazanog perioda, uz nekoliko godina vrlo niske inflacije ili pada potrošačkih cijena tokom 2010-ih (Slika 6). Ovaj obrazac naglo se promijenio nakon perioda pandemije COVID-19 i naknadnih globalnih šokova cijena energije i sirovina, pri čemu je inflacija dosegla približno 14% u 2022. godini, prije nego što je opala u 2023. godini. Ova epizoda pokazuje izloženost ekonomije BiH vanjskim cjenovnim kretanjima, uključujući cijene energije. To je relevantno za NDC3.0 jer promjene u energetskom miksu, energijskoj efikasnosti i ovisnosti o uvoznoj energiji mogu uticati na izloženost privrede budućim šokovima cijena energije i s tim povezanim inflatornim pritiscima. Očigledno, prilagođavanje u sistemu je prilično brzo.



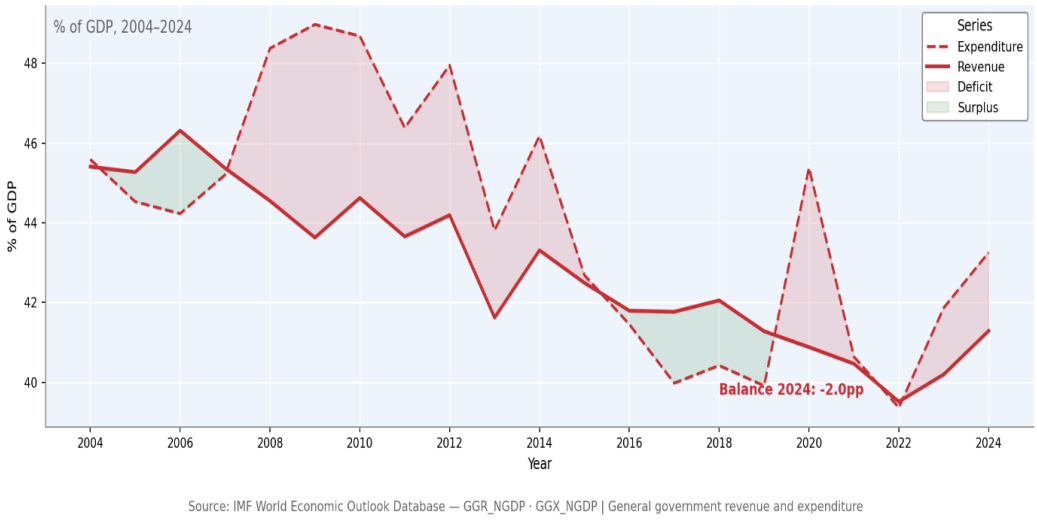
Slika 6. Inflacija, potrošačke cijene (godišnje %)u BiH, 2006-2023

Bosna i Hercegovina je relativno otvorena ekonomija, u kojoj i izvoz i uvoz roba i usluga predstavljaju značajne udjele u BDP-u. Izvoz se tokom posmatranog perioda znatno povećao, što ukazuje na snažniju integraciju u međunarodna tržišta, ali je uvoz dosljedno ostao viši, a trgovinski bilans negativan (Slika 7). Jaz se tokom pojedinih dijelova perioda sužavao, ali se ponovo proširio nakon postpandemijskog oporavka, pri čemu grafikon ukazuje na vanjskotrgovinski deficit od oko 13,4 procentna poena BDP-a u 2024. godini. Ova vanjska ovisnost posebno je relevantna za NDC3 jer će makroekonomske koristi od investicija povezanih s klimom dijelom ovisiti o njihovom domaćem sadržaju: investicije koje se u velikoj mjeri oslanjaju na uvoznu opremu i tehnologije mogu generisati manje kratkoročne domaće multiplikatore od investicija podržanih domaćom proizvodnjom i uslugama.



Slika 7. Izvoz i uvoz roba i usluga (% BDP-a) u BiH, 2004-2024

Prihodi i rashodi vlade ostali su visoki u odnosu na BDP tokom cijelog posmatranog perioda, dok je fiskalni bilans oscilirao između perioda deficita i relativne uravnoteženosti ili suficita. Fiskalni pritisci bili su posebno vidljivi tokom velikih ekonomskih poremećaja, uključujući globalnu finansijsku krizu i period pandemije COVID-19, dok grafikon ukazuje na deficit od približno 2% BDP-a u 2024. godini. Fiskalna pozicija je relevantna za NDC3 jer provedba mjera ublažavanja može zahtijevati javne investicije, subvencije, sufinansiranje i druge oblike državne podrške. Sposobnost mobilizacije domaćih resursa, pristupa vanjskom finansiranju i davanja prioriteta rashodima povezanim s klimom stoga će uticati i na obim i na dinamiku provedbe NDC-a.



Slika 8. Prihodi i rashodi opće vlade (% BDP-a) u BiH, 2004-2024

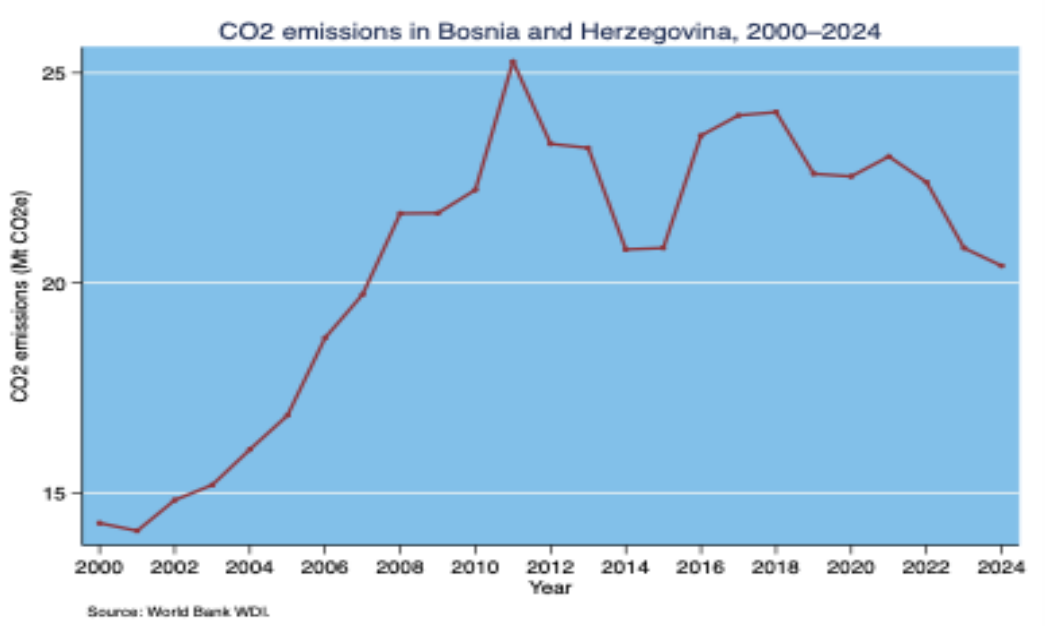
Kretanje glavnih makroekonomskih pokazatelja također ukazuje na moguće strukturne zaokrete povezane s velikim vanjskim šokovima. Globalna finansijska kriza i njene posljedice, počevši od 2008–2009, poklopile su se s izraženim usporavanjem ekonomske aktivnosti i promjenama u dinamici investicija i zaposlenosti, dok je pandemija COVID-19 proizvela oštar, ali relativno kratkotrajan poremećaj u 2020. godini. Ove epizode mogle su izmijeniti odnose između proizvodnje, kapitala i zaposlenosti te ih stoga treba izričito uzeti u obzir u postupku modeliranja. U skladu s tim, empirijska analiza testira strukturne promjene povezane s periodom nakon 2009. godine i specifičnim šokom u 2020. godini, umjesto da pretpostavlja da su odnosi ostali nepromijenjeni tokom cijelog perioda.

Svaukupno posmatrano, makroekonomski BiH pokazatelji prikazuju privredu koja je ostvarila znatna poboljšanja u zaposlenosti i investicijama i zadržala pozitivan rast tokom većeg dijela posljednje dvije

decenije, uz istovremenu izloženost demografskom padu, vanjskim šokovima, uvoznoj ovisnosti i fiskalnim ograničenjima. Ove karakteristike direktno su relevantne za dizajn i tumačenje makroekonomskog modeliranja za NDC3. Investicije i zaposlenost izdvajaju se kao posebno važni potencijalni kanali transmisije između mjera ublažavanja i ekonomske aktivnosti, dok trgovinska otvorenost, izloženost cijenama energije i fiskalni kapacitet mogu uticati na jačinu tih efekata. Historijski dokazi stoga idu u prilog okviru modeliranja koji povezuje promjene u investicijama, zaposlenosti i energetskom sistemu vezane za NDC sa širim makroekonomskim ishodima, uz izričito uvažavanje strukturnih karakteristika i ograničenja ekonomije BiH.

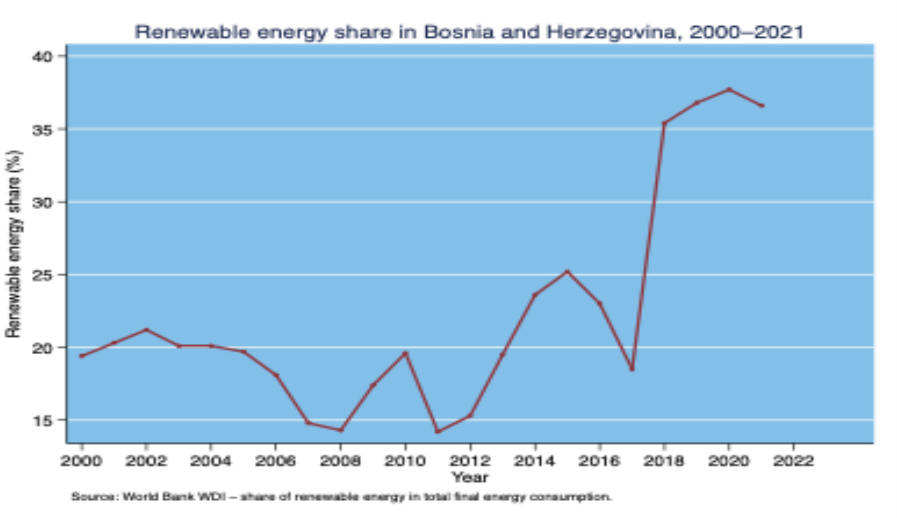
4.2. Energetska tranzicija i trendovi emisija

Pokazatelji energije i emisija predstavljaju direktnu vezu između makroekonomskih rezultata i ciljeva NDC3.0. Kretanje emisija CO_2 , udjela obnovljive energije i energijskog intenziteta pomaže u procjeni da li je ekonomski rast u BiH bio praćen promjenama u strukturi i efikasnosti korištenja energije. Ovi pokazatelji posebno su relevantni za prepoznavanje znakova tranzicije prema niskougljičnoj ekonomiji i za razumijevanje kanala kroz koje buduće mjere ublažavanja mogu uticati i na emisije i na šire ekonomske ishode. Trendovi predstavljeni u nastavku stoga dopunjuju makroekonomsku polaznu osnovu prikazujući kako su se energetski sistem i profil emisija razvijali uporedo s promjenama u ekonomskoj aktivnosti.



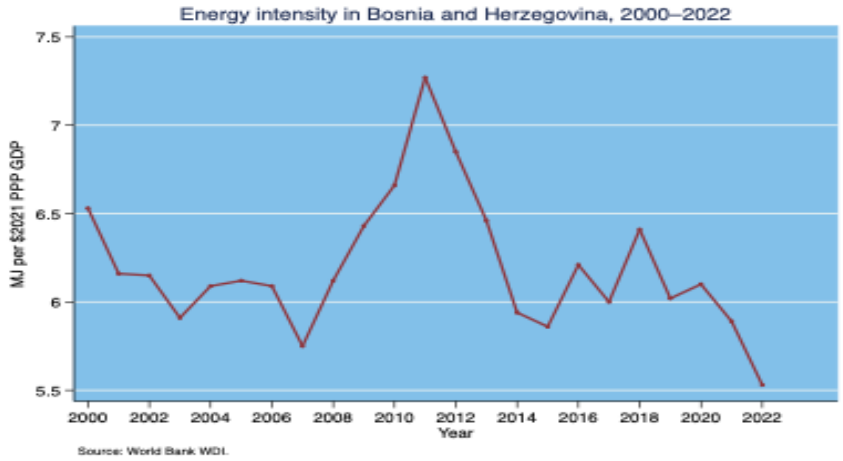
Slika 9. Emisije CO_2 u BiH, 2000-2024

Jedan od pokazatelja koji će se koristiti u modeliranju energetske tranzicije jesu emisije CO_2 , koje pružaju direktnu mjeru okolišne dimenzije koja se povezuje s makroekonomskim rezultatima. Emisije su porasle s oko 14 Mt CO_2 u 2000. godini na vrhunac od približno 25 Mt CO_2 e u 2011. godini, nakon čega su uslijedile oscilacije i uglavnom opadajući trend, dosegnuvši oko 20 Mt CO_2 e u 2024. godini. Ovo kretanje posebno je relevantno za okvir modeliranja jer omogućava da se odnos između emisija i promjena u ekonomskoj aktivnosti, investicijama i energetskom sistemu ispita kroz vrijeme. Emisije CO_2 stoga će služiti kao ključna nezavisna varijabla u procjeni historijskih odnosa i, potom, potencijalnih implikacija promjena povezanih s NDC3. Vizuelna procjena na narednoj slici ukazuje na trendove slične ponašanju realnih ekonomskih pokazatelja.



Slika 10. Udio obnovljive energije u BiH, 2000-2021

Drugi pokazatelj koji će se koristiti u modeliranju energetske tranzicije jeste udio obnovljive energije u ukupnoj finalnoj potrošnji energije. Udio obnovljive energije znatno je oscilirao tokom posmatranog perioda, opadajući s oko 19% u 2000. godini na približno 14% u 2011. godini, prije nego što je izrazito porastao u kasnijim godinama i od 2018. godine nadalje dosegao iznad 35%. Za okvir modeliranja, ovaj pokazatelj obuhvata promjene u energetskom miksu i predstavlja važnu vezu između tranzicije prema obnovljivoj energiji, ekonomske aktivnosti i emisija CO_2 . Njegove historijske varijacije stoga će se koristiti za procjenu da li su promjene u korištenju obnovljive energije sistematski povezane s makroekonomskim rezultatima i ishodima u pogledu emisija.

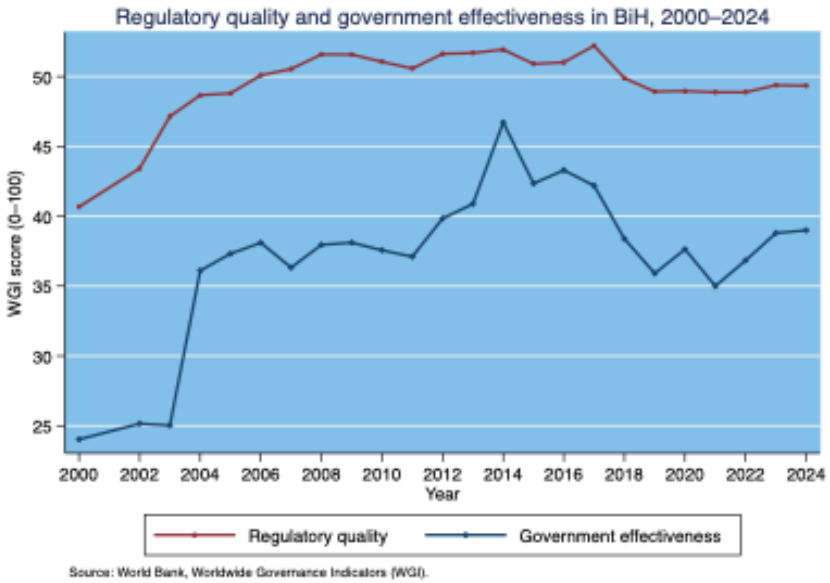


Slika 11. Energijski intenzitet u BiH, 2000-2022

Treći pokazatelj koji će se koristiti u modeliranju energetske tranzicije jeste energijski intenzitet, koji mjeri količinu energije potrebne za ostvarivanje ekonomskog outputa. Energijski intenzitet oscilirao je tokom posmatranog perioda, dosegnuvši vrhunac od oko 7,3 MJ po $2021 PPP BDP-a u 2011. godini, ali je otada uglavnom opadao, dostigavši najniži nivo od približno 5,5 u 2022. godini. Za okvir NDC3.0 modeliranja, ovaj pokazatelj obuhvata promjene u odnosu između korištenja energije i ekonomske aktivnosti te stoga može pomoći u procjeni da li ekonomski rast postaje manje energijski intenzivan. Zajedno s obnovljivom energijom i emisijama CO_2 , on pruža važan kanal za ispitivanje interakcije između ekonomskih rezultata, energijske efikasnosti i niskougljične tranzicije.

4.3. Institucionalno okruženje

Institucionalno okruženje predstavlja važan kanal kroz koji NDC mjere mogu uticati na makroekonomske ishode u Bosni i Hercegovini. Institucionalni okvir u BiH je složen, obilježen višestrukim nivoima vlasti, preklapajućim nadležnostima i zabrinutostima u pogledu institucionalne efikasnosti, uz relativno nisko povjerenje u formalne institucije, posebno među poduzetnicima i migrantima (Williams i Efendic, 2019). Istraživanja također pokazuju da se neformalne prakse i mreže često koriste kao dopuna ili zamjena za nedostatke formalnog institucionalnog okruženja (Ledeneva i Efendic, 2023). U tom kontekstu, kvalitet regulative i efikasnost vlade smatraju se posebno relevantnim za okvir modeliranja NDC3, s obzirom na širi značaj institucionalnog kvaliteta za ekonomske rezultate, investicije i provedbu politika (Efendic i Pugh, 2015).



Slika 12. Kvalitet regulative i efikasnost vlade u BiH, 2000-2024

Kvalitet regulative i efikasnost vlade koriste se za obuhvatanje institucionalne dimenzije okvira modeliranja NDC3.0. Oba pokazatelja poboljšala su se tokom ranijeg dijela posmatranog perioda, iako njihove naknadne putanje ukazuju na ograničen trajni napredak. Kvalitet regulative porastao je s oko 41 u 2000. godini na iznad 50 tokom većeg dijela perioda 2006–2017, prije nego što se posljednjih godina stabilizovao na oko 49. Efikasnost vlade poboljšavala se postepenije i dosegla vrhunac od oko 47 u 2014. godini, nakon čega je uslijedio pad i djelimičan oporavak na oko 39 u 2024. godini. Ova kretanja ukazuju na to da poboljšanja formalnog institucionalnog okruženja nisu bila kontinuirana, što je relevantno za modeliranje toga da li institucionalni uslovi utiču na investicije, ekonomske rezultate i provedbu energetske tranzicije. U našoj analizi stabilnosti dobivenih rezultata bit će ispitani i drugi institucionalni pokazatelji Svjetske banke. [7]

4.4. Preliminarni odnosi između NDC i makroekonomskih varijabli

Nadovezujući se na gore predstavljene trendove, ovaj dio ispituje kako su glavni makroekonomski, energetski, emisioni i institucionalni pokazatelji međusobno korelirali tokom posmatranog perioda. Analiza pruža početnu procjenu odnosa između ekonomske aktivnosti, investicija, zaposlenosti,

[7] Kvalitet regulative i efikasnost vlade pokazatelji su Svjetske banke i ovdje se izražavaju na skali 0–100 (što je isto kao procentualni rang), pri čemu više vrijednosti ukazuju na bolje rezultate upravljanja. WGI kombinuju informacije zasnovane na percepciji iz anketa domaćinstava i preduzeća te procjena stručnjaka koristeći model neopaženih komponenti. Izvor: Svjetska banka, *Worldwide Governance Indicators (WGI)*, 2026.

obnovljive energije, energijskog intenziteta, emisija CO_2 i institucionalnih uslova, koristeći deskriptivnu statistiku i korelacije. Ovi rezultati imaju za cilj identifikovati obrasce relevantne za naknadnu specifikaciju makroekonomskih modela i treba ih tumačiti kao deskriptivne povezanosti, a ne kao uzročne efekte.

Tabela 1. Deskriptivna statistika glavnih varijabli korištenih u okviru modeliranja NDC3

Pokazatelj	Br. opserv.	Sred. vrijednost	Std. dev.	Min	Max
Realni BDP (milijardi KM)	25	31.80	6.06	21.50	42.90
Rast BDP-a (%)	24	2.95	2.64	−3.02	7.39
Broj zaposlenih osoba (hiljada)	24	717.77	73.43	625.64	849.98
Bruto investicije u fiksni kapital (% BDP-a)	25	20.70	2.11	17.90	25.09
Fond kapitala (milijardi USD iz 2021.)	24	111.21	43.10	44.84	186.09
Emisije CO_2 (Mt CO_2 e)	25	20.48	3.38	14.10	25.27
Udio obnovljive energije (%)	24	23.66	8.48	14.20	39.74
Energijski intenzitet (MJ/$2021 PPP BDP-a)	23	6.20	0.38	5.53	7.27
Kvalitet regulative (percentilni rang)	25	49.19	3.01	40.67	52.21
Prosječan broj godina školovanja (godine)	24	8.30	1.68	6.61	10.97
Očekivani broj godina školovanja (godine)	24	12.84	0.78	11.28	13.65
Efikasnost vlade (percentilni rang)	24	37.06	5.46	24.02	46.71
Politička stabilnost (percentilni rang)	24	58.91	2.90	52.96	64.86
Vladavina prava (procjena)	24	−0.36	0.14	−0.62	−0.09

Izvor: proračun autora na osnovu podataka razrađenih u Prilogu 1.

Deskriptivna statistika potvrđuje da raspoloživi pokazatelji pružaju uglavnom dobar obuhvat perioda 2000–2024. i dovoljno varijacija za preliminarnu makroekonomsku analizu. Podaci obuhvataju znatne promjene varijabli, dok neke serije imaju kraći obuhvat, što će se uzeti u obzir pri specifikaciji modela. Kao naredni korak, korelaciona analiza koristi se za ispitivanje smjera i jačine preliminarnih odnosa između makroekonomskih rezultata, investicija i zaposlenosti s jedne strane te emisija, obnovljive energije, energijskog intenziteta i institucionalnih uslova s druge strane.

Tabela 2. Korelacije između odabranih makroekonomskih, energetskih i institucionalnih pokazatelja

Varijabla	(1)	(2)	(3)	(4)	(5)	(6)	(7)
(1) Realni BDP	1.000						
(2) Fond kapitala	0.984***	1.000					
(3) Zaposlenost	0.956***	0.950***	1.000				
(4) Udio obnovljive energije	0.723***	0.758***	0.813***	1.000			
(5) Kvalitet regulative	0.514***	0.501**	0.345*	−0.065	1.000		
(6) Emisije CO_2	0.722***	0.775***	0.674***	0.246	0.780***	1.000	
(7) Energijski intenzitet	−0.233	−0.187	−0.256	−0.421**	0.050	0.244	1.000

*Napomena: Parne korelacije. Napomena, *** p < 0,01, ** p < 0,05, * p < 0,10. Izvor: Proračuni autora na osnovu NDC3 makroekonomske baze podataka i pokazatelja objašnjenih u Prilogu 1.*

Zbog ograničenja prostora, korelaciona analiza ograničena je na varijable koje se direktno koriste u konačnim makroekonomskim i emisionim modelima. Rezultati ukazuju na snažne pozitivne korelacije između realnog BDP-a, fonda kapitala i zaposlenosti, dok su emisije CO_2 pozitivno povezane s BDP-om i stanjem kapitala. Obnovljiva energija pozitivno je korelirana s glavnim makroekonomskim varijablama, dok energijski intenzitet pokazuje uglavnom negativne, iako većinom neznačajne, korelacije s njima. Kvalitet regulative pozitivno je povezan s BDP-om i emisijama CO_2 . Većina ovih korelacija je statistički značajna, posebno snažne pozitivne korelacije između BDP-a, fonda kapitala i

zaposlenosti, koje prelaze 0,9, kao i njihove pozitivne korelacije s emisijama CO_2 . Negativna korelacija između obnovljive energije i energijskog intenziteta također je statistički značajna.

5. MAKROEKONOMSKO MODELIRANJE I EMPIRIJSKI ODNOSI ZA NDC3.0 U BIH

5.1. Uvod

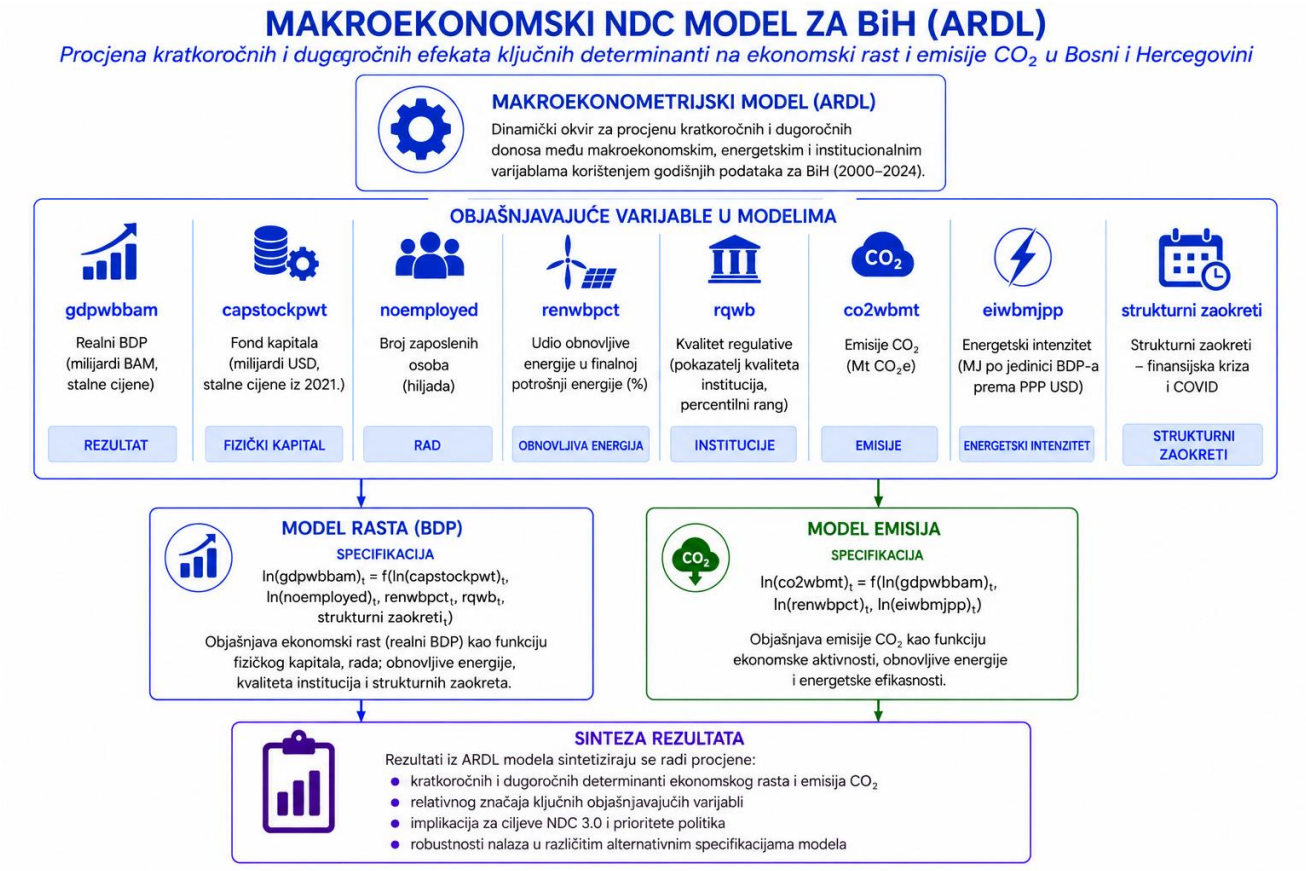
Makroekonomsko modeliranje bit će provedeno unutar empirijskog okvira za ispitivanje povezanosti ekonomske aktivnosti, emisija i odabranih pokazatelja investicija, tržišta rada, energije i institucija relevantnih za NDC3.0. Nadovezujući se na deskriptivne dokaze predstavljene u prethodnim dijelovima, analiza ide dalje od uočenih trendova i korelacija kako bi istražila dinamičke odnose među glavnim varijablama i procijenila njihovu ekonomsku i statističku relevantnost u makroekonomskim modelima.

Važna karakteristika našeg empirijskog pristupa jeste razlikovanje kratkoročne dinamike (nekoliko godina) i dugoročnih odnosa (nekoliko decenija). Ovo razlikovanje posebno je relevantno u kontekstu NDC3.0, budući da investicije, promjene u energetskom miksu, poboljšanja energijske efikasnosti i institucionalne reforme mogu proizvesti različite efekte na različitim vremenskim horizontima. Neke mjere mogu podrazumijevati troškove prilagođavanja ili relativno ograničene neposredne efekte, dok se njihove implikacije za proizvodne kapacitete, ekonomski rast, potrošnju energije i emisije mogu ostvarivati tek postepeno. Istovremeno, kratkoročna kretanja mogu odražavati oscilacije poslovnog ciklusa, vanjske šokove ili privremena prilagođavanja, a ne trajne strukturne odnose. Razlikovanje ovih efekata pruža informativniju osnovu za razumijevanje makroekonomskih implikacija zelene tranzicije.

Ostatak ovog dijela organizovan je kako slijedi. Dio 5.2 uspostavlja konceptualni okvir i identifikuje glavne kanale transmisije kroz koje investicije, uslovi na tržištu rada, energetske varijable i institucionalni faktori mogu uticati na ekonomsku aktivnost i emisije. Dio 5.3 predstavlja ekonometrijski pristup, uključujući svojstva vremenskih serija podataka i strategiju modeliranja korištenu za razlikovanje kratkoročnih od dugoročnih efekata. Dio 5.4 razvija model rasta za ispitivanje glavnih odrednica ekonomske aktivnosti, dok Dio 5.5 uvodi model emisija usredsređen na odnos između ekonomske aktivnosti, energetske tranzicije i emisija. Dio 5.5 pruža različite provjere stabilnosti prikazanih rezultata, dok Dio 5.6. sintetizira nalaze i razmatra njihove implikacije za daljnji razvoj okvira makroekonomskog modeliranja NDC3.0.

5.2. Konceptualni okvir i kanali transmisije

Konceptualni okvir organizovan je kroz dva usko povezana empirijska modela i vizuelno je predstavljen na Slici 13. Prvi skup odnosa ispituje makroekonomsku dimenziju tranzicije povezujući realnu ekonomsku aktivnost s investicijama, uslovima na tržištu rada, institucionalnim kvalitetom, energetskom strukturom, energijskom efikasnošću i strukturnim zaokretima u posmatranom periodu. Drugi se fokusira na okolišnu dimenziju povezujući emisije CO_2 s nivoom ekonomske aktivnosti i ključnim karakteristikama energetskog sistema. Ova struktura modela omogućava da se ekonomske i okolišne implikacije tranzicije analiziraju odvojeno, uz uvažavanje izričite veze između njih.



Slika 13. Predloženi konceptualni okvir za NDC makroekonomsko modeliranje

Izvor: Doprinos autora i vizuelna interpretacija pomoću AI

Prvi NDC model rasta zasnovan je na konvencionalnom, ali proširenom konceptualnom okviru proizvodne funkcije, u kojem je output primarno određen proizvodnim ulaznim faktorima fizičkog kapitala i rada (Solow, 1956). Fond kapitala (FIZIČKI KAPITAL) obuhvata akumuliranu proizvodnu kapitalnu osnovu privrede, dok broj zaposlenih osoba (RAD) predstavlja ulazni faktor rada. Za potrebe NDC3.0, ovaj konvencionalni proizvodni odnos proširen je kako bi uključio energetsku i institucionalnu dimenziju ekonomskih rezultata. Obnovljiva energija (OBNOVLJIVA ENERGIJA) obuhvata promjene u udjelu obnovljive energije u finalnoj potrošnji energije, dok kvalitet regulative (INSTITUCIJE) predstavlja institucionalno okruženje u kojem se odvijaju investicije, alokacija resursa i strukturna transformacija. Model također uključuje kontrole strukturnih zaokreta za period finansijske krize nakon 2008. godine, kao i šok pandemije COVID-19 u 2020. godini, čime se uvažavaju strukturne promjene u makroekonomskom okruženju tokom posmatranog perioda. U skladu s tim, proširena specifikacija proizvodne funkcije objašnjava realni BDP kao funkciju fizičkog kapitala, rada, ljudskog kapitala, obnovljive energije i institucionalnog kvaliteta, uslovljeno identifikovanim strukturnim zaokretima, kako je prikazano na Slici 13 i u sljedećoj početnoj specifikaciji:

$$ln\ GDP_t = f(ln\ CAPSTOCK, lnEMP_t, MYS_t, RQ_t, REN_t, EI_t),$$

gdje $ln\ GDP_t$ označava prirodni logaritam realnog bruto domaćeg proizvoda, $ln\ CAPSTOCK_t$ je prirodni logaritam akumulacije kapitala, lnEMP_t se odnosi na broj zaposlenih u logaritamskoj formi, je ljudski kapital aproksimiran prosječnim brojem godina školovanja, RQ_t je institucionalna varijabla koja obuhvata kvalitet regulative, REN_t je udio obnovljive energije u finalnoj potrošnji energije i EI_t energijski intenzitet, t označava godinu promatranja. Općenito se očekuje da investicije, zaposlenost i kvalitet regulative podržavaju ekonomsku aktivnost, dok se efekti obnovljive energije i

energijskog intenziteta mogu razlikovati između kratkog i dugog roka. Međutim, prosječan broj godina školovanja (*MYS*) i energijski intenzitet (*EI*) isključeni su u postupku modeliranja iz konačnog modela jer se nisu dobro uklopili u model, što se detaljnije razrađuje u nastavku.

Drugi NDC model obuhvata vezu između ekonomske aktivnosti i emisija. Ekonomski rast može povećati emisije kroz veću proizvodnju, potrošnju i potražnju za energijom. Međutim, jačina ovog efekta u znatnoj mjeri ovisi o energetskoj strukturi privrede. Veće oslanjanje na obnovljivu energiju i poboljšanja energijske efikasnosti mogu omogućiti širenje ekonomske aktivnosti uz manje odgovarajuće povećanje emisija. Odnos emisija stoga pruža empirijski prikaz mjere u kojoj ekonomska aktivnost i emisije mogu postepeno postati razdvojeni. Specificiran je kako slijedi:

$$\ln CO2t = f(ln\ GDPt, lnRENt, lnEIt),$$

gdje $\ln CO2t$ označava emisije ugljikovog dioksida, $ln\ GDPt$ realni bruto domaći proizvod, $lnRENt$ udio obnovljive energije u finalnoj potrošnji energije, a $lnEIt$ energijski intenzitet, dok ln označava prirodni logaritam, a t označava godinu promatranja indikatora. Općenito se očekuje da ekonomska aktivnost i energijski intenzitet povećavaju emisije, dok se očekuje da veći udio obnovljive energije smanjuje emisije.

Konceptualni i modelski okvir je specificiran i reduciranoj formi. BDP i emisije CO_2 zadržani su kao glavni makroekonomski, odnosno klimatski ishodi, dok je broj objašnjavajućih varijabli i jednačina ograničen s obzirom na dužinu i učestalost raspoloživih vremenskih serija. Cilj nije reprodukovati sve interakcije unutar privrede i energetskog sistema, nego identifikovati skup empirijski izvodljivih odnosa koji obuhvataju glavne kanale transmisije relevantne za NDC3.0. Naredni dio prenosi ove konceptualne relacije u ekonometrijski okvir koji omogućava sposoban da se razlikuje kratkoročna dinamika od dugoročnih odnosa varijabli u modelu.

5.3. Ekonometrijski pristup makroekonomskom modeliranju

Empirijska analiza koristi godišnje podatke vremenskih serija za BiH koji obuhvataju period 2000–2023. S obzirom na relativno mali broj godišnjih opservacija, analiza primjenjuje reducirane modelske specifikacije s ograničenim brojem objašnjavajućih varijabli i pomaka. Autoregresijski okvir s distribuiranim pomacima (ARDL) posebno je pogodan u ovom kontekstu jer prihvata varijable koje su I(0) ili I(1) i kombinuje kratkoročnu dinamiku i dugoročne odnose unutar jedinstvene strukture modeliranja (Pesaran, Shin i Smith, 2001). Uključivanjem pomaknutih zavisnih i objašnjavajućih varijabli, ARDL pristup također pruža određenu fleksibilnost u rješavanju potencijalne endogenosti koja proizlazi iz vremenske povratne sprege između ekonomskih ishoda i njihovih determinanti (Wooldridge, 2020).

Prije procjene modela, svojstva vremenskih serija varijabli ispituju se testovima jediničnog korijena, uključujući prošireni Dickey-Fullerov (ADF) test (Dickey i Fuller, 1979). Varijable se ispituju u nivoima i prvim diferencijama i, gdje je potrebno, koriste se dodatni testovi za ocjenu njihovog reda integrisanosti. Ovaj korak je važan jer je standardni ARDL okvir testiranja granica primjenjiv na kombinacije I(0) i I(1) varijabli, ali ne i na varijable koje su I(2) ili višeg reda. Poseban oprez stoga je potreban tamo gdje dokazi o jediničnom korijenu ukazuju na mogući viši red integrisanosti.

ARDL modeli se potom procjenjuju za odnose BDP-a i CO_2 predstavljene u Dijelu 5.1. S obzirom na ograničenu veličinu uzorka, maksimalna struktura pomaka namjerno je ograničena, a preferirane specifikacije biraju se korištenjem informacijskih kriterija zajedno s dijagnostičkim performansama i ekonomskom interpretabilnošću. Specifikacija BDP-a dodatno kontroliše strukturne promjene povezane s periodom finansijske krize nakon 2008. godine i šokom pandemije COVID-19 u 2020. godini.

5.4. NDC model rasta za BiH

Ovaj dio razvija empirijski model ekonomske aktivnosti u BiH na osnovu odnosa rasta predstavljenog u Dijelu 5.1. Empirijska analiza najprije ispituje svojstva vremenskih serija i red integrisanosti korištenih varijabli, nakon čega slijedi ARDL procjena i testiranje dugoročnog odnosa (Tabela 3 u nastavku). Rezultati pokazuju da su gotovo sve varijable koje posmatramo nestacionarne u nivoima, ali postaju stacionarne nakon prvog diferenciranja. Ove varijable se stoga mogu tretirati kao I(1), čime je zadovoljen uslov reda integrisanosti za primjenu ARDL pristupa testiranja granica.

Tabela 3. Rezultati proširenog Dickey-Fullerovog testa jediničnog korijena

Varijabla	ADF statistika, nivo	ADF statistika, prva diferencija	Red integrisanosti
Realni BDP (ln)	−1.990	−4.244***	I(1)
Fond kapitala (ln)	−2.089	−1.845	I(1)†
Broj zaposlenih osoba (ln)	−2.334	−5.069***	I(1)
Udio obnovljive energije	−1.714	−4.642***	I(1)
Kvalitet regulative	−2.710	−3.268**	I(1)

Napomene: *** p < 0,01, ** p < 0,05, * p < 0,10. ADF testovi provedeni su u nivoima i prvim diferencijama. † Konvencionalno ADF/DF-GLS testiranje ne odbacuje jedinični korijen u prvoj diferenciji fonda kapitala. Međutim, Zivot–Andrewsov test koji dopušta endogeni strukturni zaokret u odsječku odbacuje nultu hipotezu o jediničnom korijenu za prvu diferenciju (ZA = −5,806), identifikujući strukturni lom u 2010. godini. Fond kapitala se stoga tretira kao I(1) kada se uvaži strukturna promjena. Izvor: proračuni autora korištenjem ekonometrijskog softvera STATA 14.

Međutim, prosječan broj godina školovanja (MYS), koji je razmatran kao aproksimacija ljudskog kapitala u modelu rasta i konvencionalna odrednica ekonomske aktivnosti, ostao je nestacionaran nakon prvog diferenciranja i postao stacionaran tek nakon drugog diferenciranja, što ukazuje na I(2) proces. Stoga je isključen iz ARDL specifikacije. Ovo isključenje odražava svojstva vremenskih serija raspoloživog pokazatelja, a ne teorijsku relevantnost ljudskog kapitala za ekonomski rast. Slično tome, energijski intenzitet (EI) isključen je jer je pogoršao dijagnostičke performanse ARDL modela do neprihvatljivog nivoa.

Prije tumačenja procijenjenih koeficijenata, adekvatnost preferirane specifikacije ocjenjuje se nizom dijagnostičkih testova nakon procjene, prikazanih u sljedećoj tabeli (Tabela 4). Breusch–Godfreyjevi LM testovi ne odbacuju nultu hipotezu o odsustvu serijske korelacije reziduala ni pri prvom pomaku ni do drugog pomaka. Breusch–Pagan/Cook–Weisbergov test isto tako ne pruža dokaze o heteroskedastičnosti. Zajednički test asimetrije i spljoštenosti ne odbacuje normalnost reziduala, dok Ramseyjev RESET test ne pruža dokaze o pogrešnoj specifikaciji funkcionalnog oblika. Sveukupno, ove dijagnostike ukazuju na to da štedljiva ARDL specifikacija zadovoljavajuće funkcioniše u pogledu ponašanja reziduala i funkcionalnog oblika.

Tabela 4. Dijagnostika ARDL modela za model rasta

Dijagnostika	Statistika/rezultat	p-vrijednost	Zaključak
Koeficijent korekcije greške	−0.635***	0.001	Negativan i značajan; podržava prilagođavanje prema procijenjenom dugoročnom odnosu
Test granica	Nije prim.	—	Uzorak premalen u odnosu na broj procijenjenih koeficijenata; nema formalnog zaključka testa
BG LM, pomak 1	$\chi^2 = 0.312$	0.576	Nema dokaza o serijskoj korelaciji prvog reda
BG LM, pomak 2	$\chi^2 = 2.115$	0.347	Nema dokaza o serijskoj korelaciji do drugog pomaka
Heteroskedastičnost	$\chi^2 = 0.15$	0.700	Nema dokaza o heteroskedastičnosti

Dijagnostika	Statistika/rezultat	p-vrijednost	Zaključak
Normalnost reziduala	$\chi^2 = 1.45$	0.485	Normalnost nije odbačena
Ramsey RESET	F = 0.49	0.701	Nema dokaza o pogrešnoj specifikaciji funkcionalnog oblika
Prilagođeni R^2	0.910	—	Visoka objašnjavajuća moć nakon prilagođavanja za složenost modela
RMSE	0.0080	—	Mala rezidualna greška predviđanja
AIC	−149.958	—	Podržava odabranu štedljivu specifikaciju
BIC	−136.332	—	Prikazan kao dopunski kriterij za izbor modela

Napomene: *** p < 0,01, ** p < 0,05, * p < 0,10. Preferirana specifikacija je ARDL(1,1,1,1,1,0,0), odabrana korištenjem AIC-a uz maksimalnu dužinu pomaka od jedan. Izvor: proračuni autora korištenjem ekonometrijskog softvera STATA 14.

Nakon provjere dijagnostika, možemo preći na tumačenje rezultata. Rezultirajući preliminarni model rasta povezuje realni BDP sa fondom kapitala, zaposlenošću i udjelom obnovljive energije. Ova specifikacija zadržava dvije konvencionalne odrednice ekonomske aktivnosti — kapital i zaposlenost — uz uključivanje obnovljive energije kao glavne objašnjavajuće varijable povezane s NDC-om. Model ima snažnu objašnjavajuću moć, s R^2 od približno 0,96, što ukazuje na to da uključene varijable i dinamička struktura objašnjavaju oko 96% uočene varijacije u dinamici realnog BDP-a tokom perioda procjene. Ova visoka objašnjavajuća snaga modela, zajedno sa zadovoljavajućom dijagnostikom, podržava empirijsku adekvatnost specifikacije.

Tabela 5. Model rasta: ARDL procjene korekcije greške

Varijabla	Koeficijent	Std. greška	p-vrijednost
Koeficijent prilagođavanja			
Član korekcije greške, ECT(−1)	−0.635***	0.143	0.001
Dugoročni efekti			
Fond kapitala (ln)	0.379***	0.059	<0.001
Broj zaposlenih osoba (ln)	0.689***	0.155	0.001
Udio obnovljive energije	−0.00016	0.00139	0.910
Kvalitet regulative	0.00579*	0.00318	0.096
Kontrola strukturnog loma nakon 2008.	−0.168***	0.039	0.001
Kontrola strukturnog loma COVID-2020	−0.101***	0.026	0.003
Kratkoročni efekti			
Δ Fond kapitala (ln)	−0.336	0.296	0.281
Δ Broj zaposlenih osoba (ln)	0.220*	0.110	0.070
Δ Udio obnovljive energije	−0.00132	0.00075	0.105
Δ Kvalitet regulative	−0.00427	0.00293	0.173
Δ Kontrola strukturnog loma nakon 2008.	−0.107***	0.018	<0.001
Δ Kontrola strukturnog loma COVID-2020	−0.064***	0.009	<0.001
Konstanta	6.606***	1.624	0.002

Napomene: Zavisna varijabla je promjena prirodnog logaritma realnog BDP-a u reprezentaciji korekcije greške (Δln realnog BDP-a). *** p < 0,01, ** p < 0,05, * p < 0,10. Kontrola za period nakon 2008. obuhvata trajni strukturni pomak nakon globalne finansijske krize, dok kontrola COVID-2020 obuhvata specifičan šok iz 2020. godine. Relevantne dijagnostike: ARDL(1,1,1,1,1,0,0), EC1 reprezentacija; N = 23; R^2 = 0,955; prilagođeni R^2 = 0,910; AIC = −149,958; BIC=136,32. Izvor: proračuni autora korištenjem ekonometrijskog softvera STATA 14.

Procijenjeni koeficijent korekcije greške je negativan i statistički značajan, što ukazuje na relativno snažan mehanizam prilagođavanja. Njegova veličina sugeriše da se približno 64% odstupanja od procijenjenog dugoročnog odnosa koriguje u roku od jedne godine. To ide u prilog postojanju smislene dinamike dugoročnog prilagođavanja.

Dugoročne procjene identifikuju fizički kapital i zaposlenost kao glavne proizvodne faktore povezane s realnim BDP-om. Povećanje fonda kapitala od 1% povezano je s povećanjem realnog BDP-a od približno 0,38% u dugom roku, dok je povećanje broja zaposlenih osoba od 1% povezano s povećanjem od približno 0,69%. Ovi nalazi u skladu su s okvirom proizvodne funkcije na kojem se model zasniva i naglašavaju važnost i akumulacije kapitala i iskorištenosti rada za proizvodne kapacitete BiH.

Obnovljiva energija ne pokazuje statistički značajnu direktnu dugoročnu povezanost s BDP-om. Kvalitet regulative, međutim, ima pozitivan efekat koji je statistički značajan na nivou od 10%, pružajući određene dokaze da su poboljšanja regulatornog okruženja povezana sa snažnijim ekonomskim rezultatima na duži rok. Kontrolne varijable koje prate efekte strukturnih zaokreta također su negativne i statistički značajne. Procijenjeni koeficijenti impliciraju uslovnu negativnu razliku u nivou BDP-a od približno 15% za period nakon 2008. godine i oko 10% za šok pandemije COVID-19. Ovi relativno veliki negativni efekti potvrđuju važnost uvažavanja velikih strukturnih poremećaja u modelu rasta, ali ih treba posmatrati kao uslovne efekte strukturnih lomova, a ne kao uzročne procjene ukupnih ekonomskih troškova globalne finansijske krize ili pandemije.

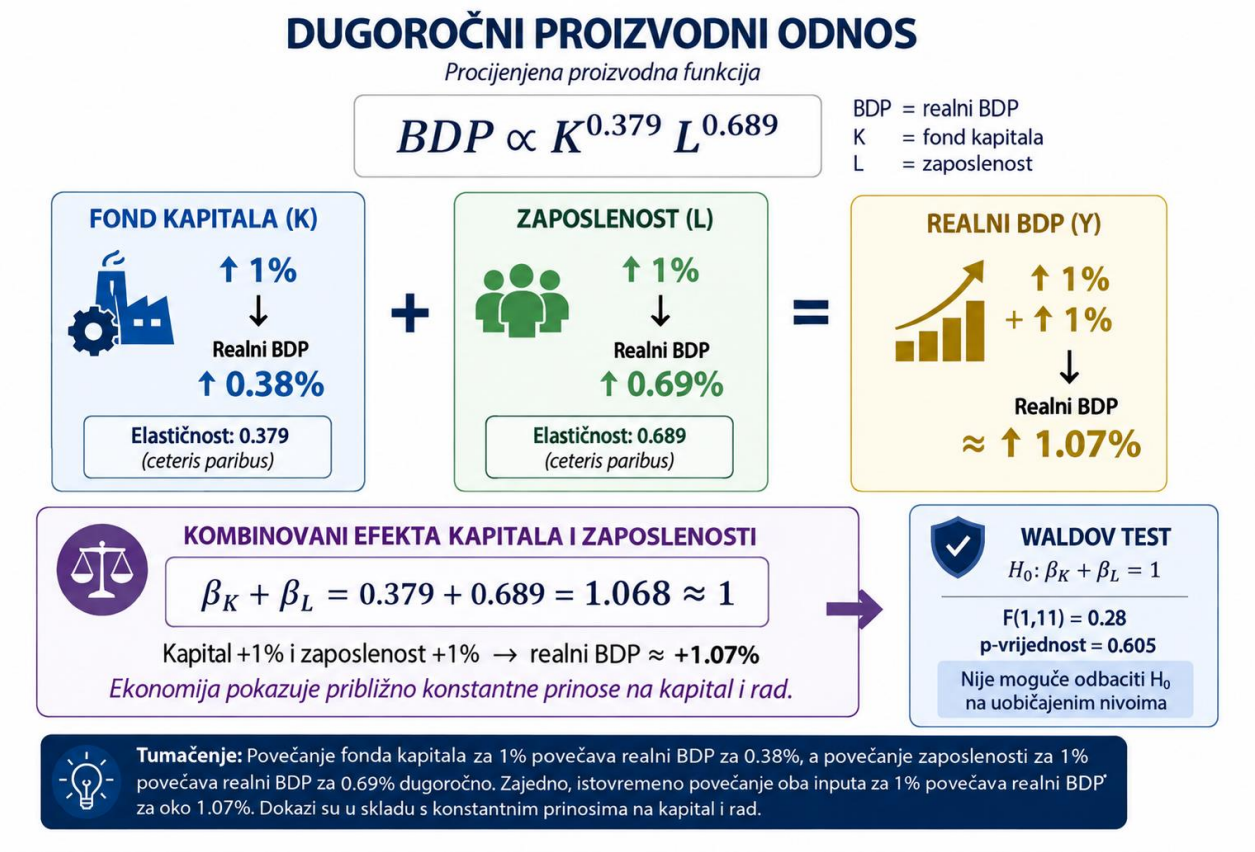
Kratkoročni efekti manje su izraženi. Zaposlenost ostaje pozitivno povezana s BDP-om i statistički je značajna na nivou od 10%: povećanje zaposlenosti od 1% povezano je s povećanjem realnog BDP-a od približno 0,22% u kratkom roku. Kratkoročne promjene fonda kapitala, obnovljive energije i kvaliteta regulative nisu statistički značajne, dok obje kontrole strukturnih lomova ostaju negativne i značajne.

Sveukupno, rezultati identifikuju akumulaciju kapitala i zaposlenost kao glavne dugoročne proizvodne faktore povezane s ekonomskom aktivnošću u BiH, pri čemu zaposlenost predstavlja i važan kratkoročni kanal transmisije. Za NDC3.0 to sugeriše da investicije koje šire proizvodnu bazu kapitala mogu podržati dugoročniju ekonomsku aktivnost, dok otvaranje radnih mjesta predstavlja važan kanal kroz koji strukturne i zelene investicije mogu generisati šire ekonomske koristi.

Važan dodatni nalaz proizlazi kada se dugoročne elastičnosti kapitala i zaposlenosti razmatraju zajedno. Procijenjeni proizvodni odnos može se izraziti kao:

$$GDP \propto K^{0.379} \times L^{0.689}$$

što implicira kombinovanu elastičnost od 1,068. Još važnije, Waldov test koji smo proveli ne odbacuje hipotezu da je zbir dviju posmatranih elastičnosti jednak jedinici. Procijenjeni proizvodni odnos stoga je statistički konzistentan s konstantnim prinosima na kapital i rad: istovremeno povećanje oba proizvodna ulazna faktora od 1% bilo bi povezano s povećanjem realnog BDP-a od približno 1%. To pruža posebno intuitivnu validaciju okvira proizvodne funkcije korištenog u NDC3.0 modelu rasta i naglašava komplementarne uloge akumulacije kapitala i zaposlenosti u održavanju dugoročnih proizvodnih kapaciteta BiH. Slijedi vizuelna interpretacija dobijenih rezultata.



Slika 14. Dugoročni proizvodni odnos rasta

Izvor: procjene autora u STATA 14 i vizuelna interpretacija pomoću AI

5.5. NDC model emisija za BiH

Drugi komplementarni dio modeliranja razvija empirijski model emisije ugljikovog dioksida u BiH, slijedeći koncept emisije predstavljen u poglavlju 5.1. Model dopunjuje prethodnu analizu rasta ispitujući kako su promjene u ekonomskoj aktivnosti i energetskoj strukturi povezane s emisijama kroz vrijeme. Emisije CO_2 inicijalno se modeliraju kao funkcija realnog BDP-a, udjela obnovljive energije i energijskog intenziteta, čime se glavni makroekonomski pokretač emisija povezuje s dva faktora vezana za energiju koji su od direktne važnosti za tranziciju NDC3.0.

Kao i u prethodnom modelu, svojstva vremenskih serija emisije CO_2 ispitana su istim ADF postupkom testiranja, koji je potvrdio da su realni BDP, obnovljiva energija i energijski intenzitet integrisani prvog reda, I(1). Dodatni testovi za emisije CO_2 (Tabela 3) ukazuju na to da je serija nestacionarna u nivoima, ali postaje stacionarna nakon prvog diferenciranja te se stoga također može klasifikovati kao I(1). Slijedom toga, sve varijable uključene u model emisije zadovoljavaju uslove reda integrisanosti za primjenu ARDL pristupa. Važno je istaći da test granica snažno odbacuje nultu hipotezu o nepostojanju odnosa u nivoima na svim uobičajenim nivoima statističke značajnosti, pružajući dokaze o stabilnom dugoročnom odnosu između emisije CO_2 i njihovih odrednica.

U nastavku je proveden niz dijagnostičkih testova radi ocjene adekvatnosti preferirane specifikacije emisie CO_2. Breusch–Godfreyjevi LM testovi ne odbacuju nultu hipotezu o odsustvu serijske korelacije reziduala. Breusch–Pagan/Cook–Weisbergov test isto tako ne pruža dokaze o heteroskedastičnosti. Zajednički test asimetrije i spljoštenosti ne odbacuje normalnost reziduala, dok Ramseyjev RESET test ne pruža dokaze o pogrešnoj specifikaciji funkcionalnog oblika. Sveukupno, ove dijagnostike ukazuju

na to da je estimirana ARDL specifikacija emisija statistički dobro postavljena i pruža zadovoljavajuću ekonomsku osnovu za tumačenje njenih kratkoročnih i dugoročnih odnosa (Tabela 6).

Tabela 6. Dijagnostika ARDL modela za model emisija

Dijagnostika	Statistika/rezultat	p-vrijednost	Zaključak
Koeficijent korekcije greške	−0.832***	<0.001	Negativan i značajan; podržava prilagođavanje prema dugoročnom odnosu
Test granica – F-test	38.573	<0.001	Podržava odnos u nivoima
Test granica – t-test	−11.268	<0.001	Podržava odnos u nivoima
Zajednička odluka testa granica	Odbacivanje	—	Utvrđen dugoročni odnos
BG LM, pomak 1	$\chi^2 = 0.051$	0.822	Nema serijske korelacije prvog reda
BG LM, pomak 2	$\chi^2 = 0.095$	0.954	Nema serijske korelacije do drugog pomaka
Heteroskedastičnost	$\chi^2 = 0.11$	0.745	Nema dokaza o heteroskedastičnosti
Normalnost reziduala	$\chi^2 = 0.08$	0.959	Normalnost nije odbačena
Ramsey RESET	F = 0.18	0.908	Nema dokaza o pogrešnoj specifikaciji funkcionalnog oblika

Napomene: Zavisna varijabla je Δln emisija CO_2 . ARDL(1,0,0,0), EC1 reprezentacija; N = 22; R^2 = 0,901; prilagođeni R^2 = 0,877; AIC = −102,569; BIC = −97,114. Test granica odbacuje nultu hipotezu o nepostojanju odnosa u nivoima na nivou od 1%. *** p < 0,01, ** p < 0,05, * p < 0,10. Izvor: proračuni autora korištenjem ekonometrijskog softvera STATA 14.

Nakon zadovoljavajuće dijagnostičke ocjene, preferirana specifikacija emisije CO_2 zadržava se za tumačenje. Reprezentacija korekcije greške ukazuje na snažno prilagođavanje prema dugoročnoj ravnoteži, dok test granica pruža jasne dokaze o stabilnom dugoročnom odnosu. Procijenjeni dugoročni koeficijenti za realni BDP, obnovljivu energiju i energijski intenzitet su statistički značajni i imaju teorijski očekivane predznake. Procijenjeni koeficijenti preferirane ARDL specifikacije prikazani su u Tabeli 7.

Tabela 7. Model emisija: ARDL procjene korekcije greške

Varijabla	Koeficijent	Std. greška	p-vrijednost
Prilagođavanje			
ECT	−0.832***	0.074	<0.001
Dugoročni efekti			
Realni BDP (ln)	1.135***	0.041	<0.001
Obnovljiva energija (ln)	−0.184***	0.025	<0.001
Energijski intenzitet (ln)	0.956***	0.105	<0.001
Kratkoročni efekti			
Δ Realni BDP (ln)	0.945***	0.090	<0.001
Δ Obnovljiva energija (ln)	−0.153***	0.021	<0.001
Δ Energijski intenzitet (ln)	0.796***	0.112	<0.001
Konstanta	−21.276***	2.059	<0.001

Napomene: Zavisna varijabla je Δln emisija CO_2 . ARDL(1,0,0,0), EC1 reprezentacija; N = 22; R^2 = 0,901; prilagođeni R^2 = 0,877; AIC = −102,569; BIC = −97,114. *** p < 0,01, ** p < 0,05, * p < 0,10.

Dobijeni rezultati pružaju snažne dokaze o kointegraciji između emisija CO_2 , realnog BDP-a, obnovljive energije i energijskog intenziteta. U skladu s tim rezultatom, procijenjeni koeficijent korekcije greške je negativan i statistički značajan na najvišem konvencionalnom nivou statističke značajnosti. Njegova veličina ukazuje na brzo prilagođavanje prema dugoročnoj ravnoteži, pri čemu se približno 83%

neravnoteže korigira u roku od jedne godine, a nakon toga ostaje svega oko 17% početnog odstupanja od ravnoteže.

Procijenjeni dugoročni koeficijenti statistički su značajni i imaju teorijski očekivane predznake. Realni BDP ima pozitivnu dugoročnu elastičnost: povećanje realnog BDP-a od 1% povezano je s povećanjem emisija CO_2 od približno 1,14% u dugom roku. Elastičnost nešto veća od jedinice ukazuje na to da su emisije tokom posmatranog perioda bile više nego proporcionalno povezane s promjenama u ekonomskoj aktivnosti. Zaista, formalni test restrikcije odbacuje hipotezu da je elastičnost BDP-a jednaka jedinici, što ukazuje na to da je procijenjena elastičnost statistički veća od jedinice. To upućuje na historijski snažnu povezanost između ekonomske aktivnosti i emisija u BiH i naglašava značaj promjena u energetskom miksu i energijskoj efikasnosti za postizanje budućeg razdvajanja.

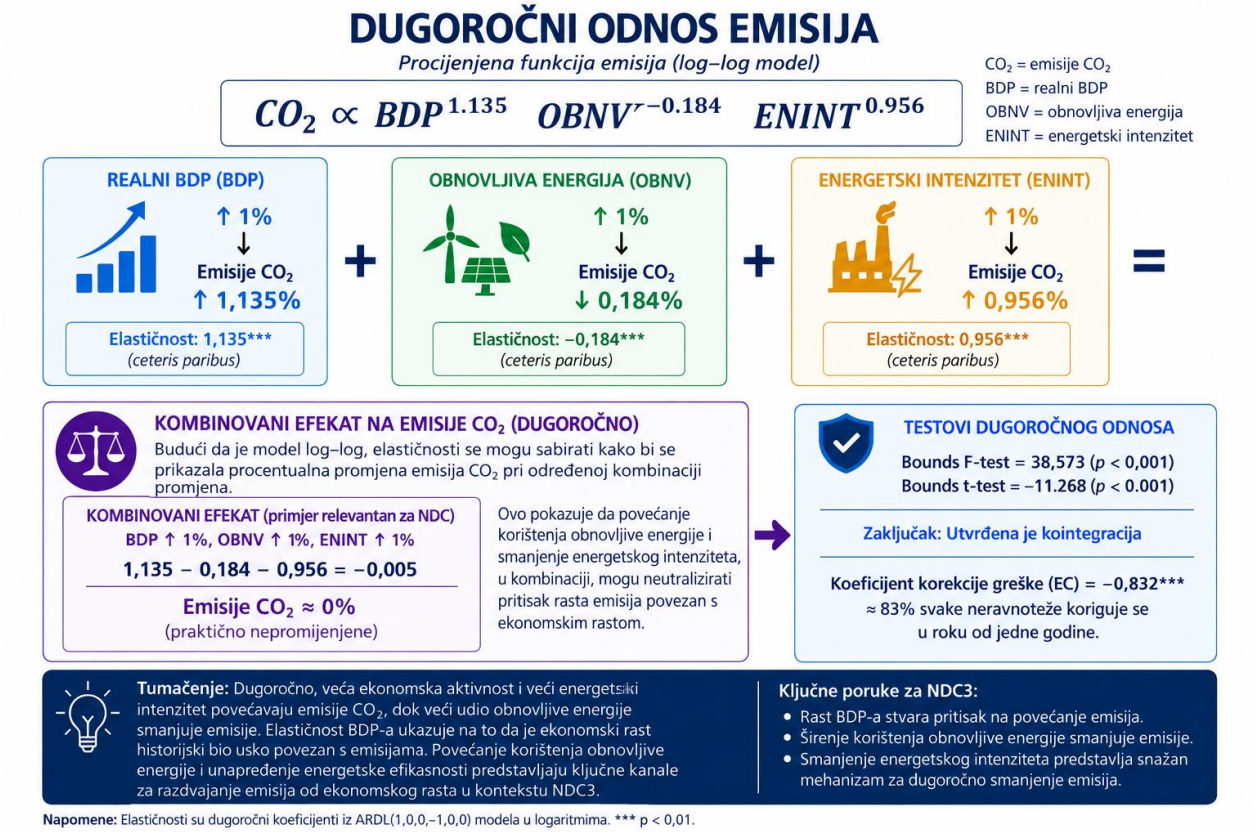
Obnovljiva energija, nasuprot tome, ima negativnu i statistički značajnu dugoročnu elastičnost. Budući da i emisije CO_2 i obnovljiva energija sada ulaze u model u logaritamskom obliku, povećanje obnovljive energije od 1% povezano je sa smanjenjem emisija CO_2 od približno 0,18% u dugom roku, uz nepromijenjene ostale faktore. Rezultat ukazuje na to da je veći prodor obnovljive energije povezan s nižim emisijama čak i nakon kontrole obima ekonomske aktivnosti i energijskog intenziteta. Time se širenje obnovljive energije identifikuje kao važan potencijalni kanal za smanjenje emisija u BiH.

Energijski intenzitet također ima očekivani pozitivan i statistički značajan dugoročni odnos s emisijama. Njegova procijenjena elastičnost iznosi približno 0,96, što implicira da je povećanje energijskog intenziteta od 1% povezano s povećanjem emisija CO_2 od približno 0,96%, uz nepromijenjene ostale faktore. Štaviše, hipoteza da je ova elastičnost jednaka jedinici ne može se odbaciti, što sugeriše približno proporcionalan dugoročni odnos između energijskog intenziteta i emisija. Obratno, smanjenje energijskog intenziteta od 1% povezano je sa smanjenjem emisija od približno 0,96%. Ovaj nalaz izdvaja poboljšanja energijske efikasnosti, uz veći prodor obnovljive energije, kao važan potencijalni kanal kroz koji se emisije mogu smanjiti bez nužnog ograničavanja ekonomske aktivnosti.

Kratkoročni koeficijenti potvrđuju dugoročne nalaze i statistički su značajni na nivou od 1%. Povećanje realnog BDP-a od 1% povezano je s povećanjem emisija CO_2 od približno 0,94% u kratkom roku, dok je povećanje obnovljive energije od 1% povezano sa smanjenjem emisija od 0,15%. Slično tome, povećanje energijskog intenziteta od 1% povezano je s povećanjem emisija CO_2 od približno 0,80%. Dosljednost predznaka između kratkoročnih i dugoročnih procjena sugeriše da su glavni kanali transmisije identifikovani modelom već vidljivi u relativno kratkom periodu, dok njihova jačina raste kako se privreda prilagođava prema dugoročnom odnosu.

Procijenjene kratkoročne i dugoročne elastičnosti, ako se posmatraju uporedno, u skladu su s teorijskim očekivanjima i pokazuju koherentan dinamički obrazac. Za sve tri varijable dugoročne elastičnosti nešto su veće po apsolutnoj vrijednosti od svojih kratkoročnih pandana, što sugeriše da se efekti pojačavaju kako se privreda i energetski sistem prilagođavaju tokom vremena. Posebno snažna dugoročna elastičnost BDP-a ukazuje na to da je ekonomska aktivnost u BiH i dalje usko povezana s emisijama, dok elastičnosti obnovljive energije i energijskog intenziteta identifikuju dva glavna kanala kroz koja se ta veza može oslabiti u kontekstu NDC3.0.

Sveukupno, model emisija pruža snažne dokaze o stabilnom dugoročnom odnosu. Procijenjene elastičnosti pružaju posebno korisnu interpretaciju za NDC3.0: nastavak ekonomske ekspanzije, u odsustvu promjena u energetskoj strukturi i efikasnosti, povezan je s pritiskom na povećanje emisija, dok povećanje obnovljive energije i smanjenje energijskog intenziteta pružaju kanale za neutralisanje tog pritiska. Ovi odnosi stoga pružaju kvantitativnu osnovu za prevođenje alternativnih pretpostavki o ekonomskom rastu, obnovljivoj energiji i energijskoj efikasnosti u njihove potencijalne implikacije za buduće emisije. Vizuelni prikaz rezultata predstavljen je u nastavku.



Slika 15. Dugoročni odnosi emisija

Izvor: procjene autora u STATA 14 i vizuelna interpretacija pomoću AI

5.6. Stabilnost procijenjenih NDC modela

U nastavku procedure ispitano je nekoliko alternativnih specifikacija modela radi ocjene stabilnosti i robusnosti preferiranih modela rasta i emisija te daljnjeg istraživanja njihovih glavnih nalaza. Ove provjere razmatrale su alternativne mjere institucionalnog kvaliteta i investicija, uključivanje trgovinske otvorenosti i ljudskog kapitala, alternativne strukture pomaka i determinističke komponente te tretman strukturnih zaokreta u modelima. Sveukupno, glavni rezultati i njihova ekonomska interpretacija ostali su stabilni, čime se podržava preferirana specifikacija prikazana iznad.

Institucionalni kvalitet u preferiranoj specifikaciji predstavljen je kvalitetom regulative (*rqwb*). Analiza osjetljivosti korištenjem alternativnih institucionalnih pokazatelja, uključujući efikasnost vlade (*ge_wb*), političku stabilnost (*ps_wb*) i vladavinu prava (*rlwbest*), nije proizvela stabilnije ni konzistentnije rezultate. Konkretno, politička stabilnost i vladavina prava nisu pokazale statistički značajne dugoročne efekte, dok su glavni nalazi za kapital i zaposlenost ostali uglavnom stabilni u alternativnim specifikacijama. Kvalitet regulative stoga je zadržan kao preferirani institucionalni pokazatelj, pružajući dokaze o pozitivnoj dugoročnoj povezanosti s realnim BDP-om.

Trgovinska otvorenost (*openness*) također je ispitana kao dodatna kontrolna varijabla u oba modela. U modelu rasta, njeno uključivanje nije poboljšalo preferiranu specifikaciju. U modelu emisije CO_2, trgovinska otvorenost bila je statistički neznačajna, dok su glavne dugoročne elastičnosti, dokazi o kointegraciji i zadovoljavajuće dijagnostike ostali suštinski nepromijenjeni. Stoga trgovinska otvorenost kao varijabla nije zadržana ni u jednoj preferiranoj specifikaciji, radi očuvanja stepena slobode za kredibilniju interpretaciju.

Javne investicije (*lnpubinvbn*) također su ispitane kao alternativna mjera investicija. Njihov dugoročni koeficijent bio je statistički neznačajan, dok su pozitivni dugoročni i kratkoročni efekti zaposlenosti ostali robusni. Međutim, kraća dostupnost podataka o javnim investicijama smanjila je period procjene na 2001–2019, a rezultirajuća specifikacija pokazala je značajnu serijsku korelaciju reziduala i nije omogućila pouzdanu provedbu nekoliko standardnih dijagnostičkih testova. Ovi rezultati stoga ne pružaju osnovu za zamjenu mjere fonda kapitala i dodatno podržavaju preferiranu specifikaciju modela ekonomskog rasta.

Kao dodatne provjere robusnosti, preferirani model rasta proširen je alternativnim mjerama ljudskog kapitala i korištenja energije. Prosječan broj godina školovanja (*MYS*) i očekivani broj godina školovanja (*EYS*) uvedeni su odvojeno kako bi se ispitalo doprinosi li ljudski kapital dodatnoj objašnjavajućoj moći, dok je energijski intenzitet (*eiwbmjpp*) dodat kako bi se ocijenilo utiče li efikasnost korištenja energije na procijenjene odnose ekonomskog rasta. Ova proširenja korištena su prvenstveno za ocjenu toga da li glavni rezultati preferirane specifikacije ostaju stabilni nakon uvođenja dodatnih teorijski relevantnih faktora. Sveukupno, ove dodatne varijable nisu bitno poboljšale model, dok su dijagnostički rezultati i dalje išli u prilog konačnoj specifikaciji, čime je dodatno podržan njen izbor kao preferiranog modela rasta.

Konačno, stabilnost modela rasta ispitana je dodavanjem linearnog vremenskog trenda. Trend je bio statistički neznačajan i u dugom i u kratkom roku, dok su glavni rezultati ostali stabilni: kapital i zaposlenost zadržali su svoje pozitivne dugoročne efekte, koeficijent prilagođavanja ostao je negativan i značajan, a efekti strukturnih zaokreta ostali su negativni. Konstantni prinosi na kapital i zaposlenost nisu se mogli odbaciti. Dijagnostika modela ostala je zadovoljavajuća, iako je specifikacija bez trenda imala nešto bolje rezultate, što dodatno podržava preferirani model.

6. ZAKLJUČCI, PREPORUKE I NAREDNI KORACI

Modeli rasta i emisije CO_2 pružaju konzistentnu sliku odnosa između ekonomske aktivnosti, proizvodnih ulaznih faktora i energetske tranzicije u BiH. Model rasta identifikuje akumulaciju kapitala i zaposlenost kao glavne dugoročne proizvodne faktore, pri čemu oba pokazuju pozitivne i statistički značajne efekte. Zaposlenost se izdvaja i kao važan kratkoročni pokretač ekonomske aktivnosti. Procijenjene dugoročne elastičnosti kapitala i zaposlenosti zajedno su konzistentne s konstantnim prinosima na ove proizvodne ulazne faktore, što dodatno podržava tumačenje modela kroz proizvodnu funkciju. Negativan i značajan koeficijent prilagođavanja ukazuje na relativno brzo prilagođavanje prema procijenjenom dugoročnom odnosu.

Model emisija pruža snažne dokaze o stabilnom dugoročnom odnosu između emisija CO_2 , ekonomske aktivnosti i karakteristika energetskog sektora. Ekonomski rast povezan je s višim emisijama CO_2 u dugom roku, dok je veći prodor obnovljive energije povezan s nižim emisijama, a viši energijski intenzitet s višim emisijama. Rezultati su stoga posebno relevantni za NDC3.0: nastavak ekonomske ekspanzije bez odgovarajućih promjena u energetskom miksu i energijskoj efikasnosti stvarao bi pritisak na rast emisije CO_2, dok širenje obnovljive energije i smanjenje energijskog intenziteta pružaju važne kanale za usklađivanje ekonomskog rasta s ciljevima smanjenja emisija.

S obzirom na relativno mali broj godišnjih opservacija, estimirani ARDL okvir ostaje relevantani empirijski pristup u postojećim dostupnostima podataka. Raspoložive vremenske serije ne pružaju dovoljno snažnu osnovu za veliki strukturni makroekonomski model. Empirijski rezultati ipak identifikuju jasne kanale transmisije koji se mogu kombinovati s pretpostavkama zasnovanim na scenarijima o obimu i dinamici intervencija NDC3.0. Konkretno, model rasta ističe akumulaciju kapitala i zaposlenost, dok model emisija identifikuje ekonomsku aktivnost, obnovljivu energiju i energijski intenzitet kao glavne kanale kroz koje se mogu ocjenjivati buduća kretanja povezana s NDC-om. Kontinuirano unapređenje osnovne baze podataka, posebno za pokazatelje energije, investicija i tržišta rada, dodatno bi ojačalo ovaj okvir.

Naredni korak je stoga prevođenje konkretnih mjera ublažavanja iz NDC3.0 u kvantitativne promjene ovih transmisionih varijabli. To bi zahtijevalo godišnje projekcije investicija povezanih s NDC-om i

njihovog doprinosa proizvodnom fondu kapitala, zaposlenosti, prodoru obnovljive energije, energijskom intenzitetu i emisijama CO_2 do 2030–2050. godine, po mogućnosti u okviru osnovnog scenarija i scenarija ublažavanja. Ovi ulazni podaci mogli bi se potom kombinovati s procijenjenim ARDL odnosima kako bi se ocijenilo na koji su način formiranje kapitala i kretanja zaposlenosti povezani s NDC-om i ekonomskom aktivnošću, te kako rezultirajući ekonomski rast, zajedno sa širenjem obnovljive energije i poboljšanjima energijskog intenziteta, utiče na buduću putanju emisije CO_2. Ovo sigurno da zahtijeva jedan dugoročniji empirijski plan i poduhvat.

7. REFERENCE

Black, S., Parry, I., Mylonas, V., Vernon, N. i Zhunussova, K. (2023). *The IMF–World Bank Climate Policy Assessment Tool (CPAT): A Model to Help Countries Mitigate Climate Change*. IMF Working Paper WP/23/128. Dostupno na: https://www.imf.org/-/media/files/publications/wp/2023/english/wpiea2023128-print-pdf.pdf.

Blanchard, O. (2021). *Macroeconomics* (8. izd.). Harlow: Pearson.

Breisinger, C., Thomas, M., & Thurlow, J. (2009). *Social Accounting Matrices and Multiplier Analysis: An Introduction with Exercises*. International Food Policy Research Institute (IFPRI).

Dickey, D. A. i Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association* 74 (366): 427–431.

Efendić, A. i Pugh, G. (2015). Institutional effects on economic performance in post-socialist transition: A dynamic panel analysis. *Acta Oeconomica* 65 (4): 503–523.

Heaps, C. (2021). *LEAP: The Low Emissions Analysis Platform. Training Exercises.* Stockholm: Stockholm Environment Institute (dostupno na: https://gggi.org/wp-content/uploads/2021/12/ENG-LEAP-TRAINING-MANUAL.pdf).

Hourcade, J. i sar. (2006). Hybrid Modeling: New Answers to Old Challenges. Introduction to the Special Issue of The Energy Journal. *The Energy Journal* Vol. SI2006/01, https://doi.org/10.5547/issn0195-6574-ej-volsi2006-nosi2-1.

Huang, Y., Kuldasheva, Z. i Salahodjaev, R. (2021). Renewable Energy and CO_2 Emissions: Empirical Evidence from Major Energy-Consuming Countries. *Energies* 14 (22): 7504.

Keynes, J. M. (1936). *The General Theory of Employment, Interest and Money*. London: Macmillan.

Ledeneva, A. i Efendić, A. (2023). There is no free lunch: Informal networking and its costs for entrepreneurs in South East Europe. *Europe-Asia Studies* 75 (4): 625–648.

Loulou, R., Goldstein, G., Kanudia, A., Lettila, A., & Remme, U. (2016). *Documentation for the TIMES Model: Part I*. Energy Technology Systems Analysis Programme (ETSAP), International Energy Agency. Dostupno na: https://www.scribd.com/document/983400225/Documentation-for-the-TIMES-Model-Part-I

Miller, R. E. i Blair, P. D. (2009). *Input–Output Analysis: Foundations and Extensions* (2. izdanje). Cambridge: Cambridge University Press.

Mirza i sar. (2022)**.** Impact of Energy Efficiency on CO_2 Emissions: Empirical Evidence from Developing Countries. Gondwana Research 106: 64–77.

Narayan, P. K. (2005). The saving and investment nexus for China: Evidence from cointegration tests. *Applied Economics* 37 (17): 1979–1990.

OECD (2024). Approaches to Linking Models to Assess the Impacts of Climate Change Mitigation Actions on Greenhouse Gas Emissions. Inclusive Forum on Carbon Mitigation Approaches Papers No. 6, OECD Publishing, Pariz.

OECD (2025). *Energy Prices and Subsidies in the Western Balkans: Reforms for a Fair and Green Future, OECD Development Pathways*. OECD Publishing, Pariz, https://doi.org/10.1787/082ea26a-en.

Pasović, E. i Efendić, A. (2018). Informal economy in Bosnia and Herzegovina – an empirical investigation. *South East European Journal of Economics and Business* 13 (2): 112-125.

Pesaran, M. H., Shin, Y. i Smith, R. J. (2001). Bounds testing approaches to the analysis of level relationships. *Journal of Applied Econometrics* 16 (3): 289–326.

Solow, R. M. (1956). A contribution to the theory of economic growth. *Quarterly Journal of Economics* 70 (1): 65–94.

Williams, N. i Efendić, A. (2019). Internal displacement and external migration in a post-conflict economy: Perceptions of institutions among migrant entrepreneurs. *Journal of International Entrepreneurship* 17 (4): 558–585.

Wooldridge, J. M. (2020). *Introductory Econometrics: A Modern Approach* (7. izdanje). Boston, MA: Cengage Learning.

Spisak slika

Slika 1. Rast stanovništva (godišnji %)u BiH, 2004-2024 7
Slika 2. Rast BDP-a (godišnji %) u BiH, 2004-2024 8
Slika 3. Nezaposlenost, ukupno (% ukupne radne snage) u BiH, 2004-2024 8
Slika 4. Stopa zaposlenosti (%) u BiH, 2000-2024 9
Slika 5. Bruto investicije u fiksni kapital (% BDP-a) u BiH, 2000-2024 10
Slika 6. Inflacija, potrošačke cijene (godišnje %)u BiH, 2006-2023 10
Slika 7. Izvoz i uvoz roba i usluga (% BDP-a) u BiH, 2004-2024 11
Slika 8. Prihodi i rashodi opće vlade (% BDP-a) u BiH, 2004-2024 11
Slika 9. Emisije CO_2 u BiH, 2000-2024 12
Slika 10. Udio obnovljive energije u BiH, 2000-2021 13
Slika 11. Energijski intenzitet u BiH, 2000-2022 13
Slika 12. Kvalitet regulative i efikasnost vlade u BiH, 2000-2024 14
Slika 13. Predloženi konceptualni okvir za NDC makroekonomsko modeliranje 17
Slika 14. Dugoročni proizvodni odnos rasta 22
Slika 15. Dugoročni odnosi emisija 25

Spisak tabela

Tabela 1. Deskriptivna statistika glavnih varijabli korištenih u okviru modeliranja NDC3 15
Tabela 2. Korelacije između odabranih makroekonomskih, energetskih i institucionalnih pokazatelja 15
Tabela 3. Rezultati proširenog Dickey-Fullerovog testa jediničnog korijena 19
Tabela 4. Dijagnostika ARDL modela za model rasta 19
Tabela 5. Model rasta: ARDL procjene korekcije greške 20
Tabela 6. Dijagnostika ARDL modela za model emisija 23
Tabela 7. Model emisija: ARDL procjene korekcije greške 23

Prilog – Tabela s opisom varijabli u NDC skupu podataka

Skraćenica	Puni naziv	Opis, izvor podataka i njihova svrha
year	Godina	Godina opservacije (2000–2024)
gdpwbbam	BDP – Svjetska banka (KM, stalne cijene)	Bruto domaći proizvod, Svjetska banka, izražen u konvertibilnim markama (KM) u stalnim cijenama; glavna serija BDP-a korištena u modeliranju.
gdpwbyoy	Međugodišnji rast BDP-a – Svjetska banka (%)	Godišnja stopa rasta BDP-a, Svjetska banka, izražena u procentima.
noemployed	Broj zaposlenih osoba	Ukupan broj zaposlenih osoba u BiH, prvenstveno na osnovu podataka Agencije za statistiku Bosne i Hercegovine; glavna mjera ulaznog faktora rada korištena u preferiranom modelu rasta.
empwbpct	Stopa zaposlenosti – Svjetska banka (%)	Omjer zaposlenosti i stanovništva, dob 15+, Svjetska banka (modelirana procjena ILO-a), izražen u procentima; alternativna mjera tržišta rada razmatrana u postupku modeliranja.
gfcfwbbm	GFCF – Svjetska banka (KM, stalne cijene)	Bruto investicije u fiksni kapital, Svjetska banka, izražene u KM u stalnim cijenama; mjera investicionog toka razmatrana u alternativnim specifikacijama rasta.
kpwt	Fond kapitala – PWT (miliona USD iz 2021., stalne cijene)	Realni fond kapitala u stalnim nacionalnim cijenama, Penn World Table (PWT), izražena u milionima američkih dolara iz 2021. godine; mjera fizičkog kapitala korištena u preferiranom modelu rasta.
co2wbmt	Emisije CO_2 – Svjetska banka (Mt CO_2 e)	Emisije CO_2 , Svjetska banka, izražene u megatonama ekvivalenta CO_2 ; glavna mjera emisija korištena u modelu emisija.
renwbpct	Udio obnovljive energije – Svjetska banka (%)	Udio obnovljive energije u ukupnoj finalnoj potrošnji energije, Svjetska banka; uključen u preferirane okvire modeliranja rasta i emisija.
eiwbmjpp	Energijski intenzitet – Svjetska banka (MJ/$2021 PPP BDP-a)	Energijski intenzitet, Svjetska banka, izražen u megadžulima po američkom dolaru BDP-a prilagođenom za PPP iz 2021. godine; uključen u preferirani model emisija i ispitan kao proširenje modela rasta.
expwbpgd	Izvoz – Svjetska banka (% BDP-a)	Izvoz roba i usluga kao procenat BDP-a, Svjetska banka; korišten pri konstrukciji pokazatelja trgovinske otvorenosti ispitanog u analizi osjetljivosti.
impwbpgd	Uvoz – Svjetska banka (% BDP-a)	Uvoz roba i usluga kao procenat BDP-a, Svjetska banka; korišten zajedno s izvozom za konstrukciju pokazatelja trgovinske otvorenosti ispitanog u analizi osjetljivosti.
ge_wb	Efikasnost vlade – WGI (0–100)	WGI pokazatelj efikasnosti vlade Svjetske banke; ispitan kao alternativna mjera institucionalnog kvaliteta u analizi osjetljivosti.
ps_wb	Politička stabilnost – WGI (0–100)	WGI pokazatelj političke stabilnosti i odsustva nasilja Svjetske banke; ispitan kao alternativna mjera institucionalnog kvaliteta u analizi osjetljivosti.
rqwb	Kvalitet regulative – WGI (0–100)	WGI pokazatelj kvaliteta regulative Svjetske banke; mjera institucionalnog kvaliteta zadržana u preferiranoj specifikaciji rasta.
rlwbest	Vladavina prava – WGI procjena (−2,5 do +2,5)	WGI procjena vladavine prava Svjetske banke; ispitana kao alternativna mjera institucionalnog kvaliteta u analizi osjetljivosti.
pubinvbn	Javne investicije – IMF ICSD (milijardi KM, nominalno)	Bruto investicije opće vlade u fiksni kapital, IMF Investment and Capital Stock Dataset 2021, izražene u milijardama KM u tekućim cijenama; ispitane kao alternativni pokazatelj investicija/javnog kapitala u analizi osjetljivosti.
mys	Prosječan broj godina školovanja – UNDP	Prosječan broj godina školovanja, podaci UNDP-a o ljudskom razvoju; pokazatelj ljudskog kapitala ispitan u analizi osjetljivosti modela rasta.
eys	Očekivani broj godina školovanja – UNDP	Očekivani broj godina školovanja, podaci UNDP-a o ljudskom razvoju; alternativni pokazatelj ljudskog kapitala ispitan u analizi osjetljivosti modela rasta.

Svi podaci prikupljeni su ili ažurirani u junu 2026. godine, a razlike u dostupnosti podataka određuju efektivne periode uzorka korištene u empirijskim modelima. Pored varijabli koje ulaze u preferirane specifikacije, baza podataka sadrži alternativne mjere BDP-a, zaposlenosti, investicija, institucionalnog kvaliteta, ljudskog kapitala, trgovinske otvorenosti i

Skraćenica	Puni naziv	Opis, izvor podataka i njihova svrha
emisija koje su korištene za analizu osjetljivosti i robusnosti. Logaritamske transformacije, trgovinska otvorenost i kontrole strukturnih lomova konstruisane su iz osnovnih varijabli tokom postupka modeliranja.		